

VŠB – TECHNICKÁ UNIVERZITA OSTRAVA
FAKULTA ELEKTROTECHNIKY A INFORMATIKY
Katedra kybernetiky a biomedicínského inženýrství

**Analýza a modelování zájmových struktur
z echokardiografie**

**Analysis and Modeling of Objects of Interest from
Echocardiography**

VŠB - Technická univerzita Ostrava
Fakulta elektrotechniky a informatiky
Katedra kybernetiky a biomedicínského inženýrství

Zadání diplomové práce

Student: **Bc. Kristýna Molnárová**
Studijní program: N2649 Elektrotechnika
Studijní obor: 3901T009 Biomedicínské inženýrství
Téma: **Analýza a modelování zájmových struktur z echokardiografie**
Analysis and Modeling of Objects of Interest from Echocardiography
Jazyk vypracování: čeština

Zásady pro vypracování:

1. Nastudování klinických poznatků k echokardiografickému vyšetření.
2. Rešerše segmentačních metod v echokardiografii.
3. Analýza testovacích echokardiografických dat s cílem identifikace zájmových objektů.
4. Návrh procedury předzpracování echokardiografických obrazů.
5. Návrh a realizace segmentační procedury pro echokardiografická obrazová data.
6. Testování navrženého segmentačního modelu na klinických obrazových datech.
7. Testování robustnosti modelu v kontextu deterministických obrazových šumů.
8. Dynamické sledování parametrů modelu v průběhu času.
9. SW aplikace pro modelování srdečních struktur z echokardiografických záznamů.
10. Zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] ARMSTRONG, William F, Thomas RYAN a Harvey FEIGENBAUM. *Feigenbaum's echocardiography*. 7th ed. Philadelphia: Wolters Kluwer Health/Lippincott Williams & Wilkins, c2010. ISBN 978-0781795579.
- [2] SURI, Jasjit S, David L WILSON a Swamy LAXMINARAYAN. *Handbook of biomedical image analysis*. New York: Kluwer Academic/Plenum Publishers, c2005. ISBN 0-306-48607-5.
- [3] JAN, Jiří. *Medical image processing, reconstruction, and restoration: concepts and methods*. Boca Raton, FL: Taylor & Francis, 2006. ISBN 0-8247-5849-8.

Vedoucí diplomové práce: **Ing. Jan Kubiček, Ph.D.**

Datum zadání: 01.09.2018

Datum odevzdání: 30.04.2019



doc. Ing. Jiří Koziorek, Ph.D.
vedoucí katedry

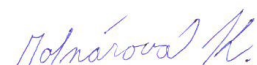


prof. Ing. Pavel Brandštetter, CSc.
děkan fakulty

Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracovala samostatně a veškeré publikace, ze kterých jsem čerpala, jsou řádně ocitovány a obsaženy ve zdrojích práce.

Ostrava 30. dubna 2019


Bc. Kristýna Molnárová

Poděkování

Ráda bych napsala poděkování vedoucímu této práce Ing. Janu Kubíčkovi, Ph.D. za odborné rady, ochotu a pomoc v rámci celé diplomové práce.

V neposlední řadě bych chtěla poděkovat rodině, příteli a kamarádům za podporu, pochopení a trpělivost v průběhu celého dlouhého studia.

Abstrakt

Tato diplomová práce se zabývá implementací algoritmu aktivních kontur na bázi statistického rozložení pixelů pro segmentaci srdečních struktur z dynamického vyšetření Echokardiografie. Implementací navrženého algoritmu a separací srdečních struktur je možno měřit parametry v srdečních síních a komorách. Aplikačním výstupem je přehledné graficko-uživatelské rozhraní obsahující všechny tyto funkcionality vytvořené v prostředí MATLAB, tak jako celý navržený kód. Výběr metody byl založen na vypracovaných publikacích z řešerše v první kapitole práce a zhodnocením poznatků z těchto vědeckých prací v ní obsažených. Teoretická část je základ problematiky echokardiografického vyšetření, ultrazvukových snímků, ultrazvuku a v neposlední řadě se opírá o klinickou problematiku a patologie zjištěné při tomto vyšetření se stanovením fyziologických parametrů srdečních struktur (srdeční komory, síně). Praktická část práce popisuje kroky v procesu celé segmentace, a to předzpracování obrazu, samotnou segmentaci a měření parametrů v separované části modelu, a to délku, šířku, těžiště a rozměr právě v separované srdeční síni nebo komoře. Konečným výsledkem této části se stává uživatelské rozhraní zahrnuje všechny tyto kroky v interaktivním a uživatelsky přijatelném provedení. Další část práce se zabývá testováním robustnosti navrženého algoritmu na snímcích uměle zatížených šumy (*Speckle, Gauss a Salt & Pepper*). Po zatížení všech datových sad snímků byla taktéž provedena jejich segmentace se stejným nastavením algoritmu jako u nativního obrazu, a poté se zjišťovala podobnost segmentovaných částí uměle zatížených šumem vzhledem k segmentovaným částem v nativních snímcích pomocí strukturální podobnosti, střední kvadratické odchylky, korelace a koeficientu DICE. Konečná část práce se tak zabývá zhodnocením těchto testovacích procedur a vyhodnocením robustnosti a úspěšnosti segmentační procedury použité v této práci při větším zatížením ultrazvukových snímků.

Abstract

That diploma thesis is interested in implementation algorithm of Active Contours based on statistical parameters of pixels for segmentation of heart structures in Echocardiography. After implementation of created algorithm and separation of heart's structures is possible to measure parametrs in ventricles and atriums of heart. The application output is grafical user interface contains all of these functionalities created in MATLAB as the all implemented codes. Chosen method was established on science publications from research in the first capture of thesis and evaluation of knowledge from these publications. Part of theory is the basis of Echokardiography, ultrasound images, ultrasound and last but not least was based on clinic problems and pathology which you find out in this examination with determination of physiological parametrs of heart structures (heart ventricules, atriums). The practical part of thesis describe steps of all segmentation process and that is preprocessing image, segmentation and meassuring parameters in separated model and that is lenght, width, center of gravity and volume of indicated by extracting from heart ventriculum or atrium. The final result is become the graphical user interface which include all of steps in interactive view for users. The next part of the thesis is dealt with testing in effectivity of implemented algorithm on images which was loaded by noise (speckle, Gaussian and Salt and Pepper noise). All of data was segmentated by the same algorithm with the same set of parametrs like in native data and then was found out the similarity between segmentated models from noisy data and segmentated models from native data by structural similarity, mean squared error, correlation and by the DICE coefficient. The end of this thesis was evaluated regarding to results of these tested procedures and thereby of implemented algorithm based on Active Contours.

Klíčová slova

Echokardiografie, aktivní kontury, segmentace obrazu, zpracování obrazu, filtrace, ultrazvuk, kardiologie, šum Salt and Pepper, Gaussův šum, šum speckle, korelace, strukturální podobnost, střední kvadratická chyba, Dice koeficient, GUI

Keywords

Echocardiography, active contours, segmentation of images, image processing, filtration, ultrasound, cardiology, Salt and Pepper noise, Gaussian noise, speckle noise, correlation, structural similarity, mean squared error, DICE coefficient, GUI

Obsah

Seznam použitých zkratk	11
Seznam obrázků	13
Seznam tabulek	18
Seznam rovnic	19
Úvod	20
TEORETICKÁ ČÁST	21
1 Rešerše: Segmentace v echokardiografických snímcích	22
1.1 Základní segmentační metody a jejich principy	22
1.1.1 Level-Set metoda	22
1.1.2 Metoda aktivních kontur	24
1.1.3 Metoda deformovaných šablon	26
1.1.4 Metoda databáze	26
1.1.5 Detekce hran	26
1.1.6 Prahování	26
1.1.7 Neuronové sítě	27
1.2 Kombinované segmentace	27
1.2.1 Aktivní tvarový model v kombinaci s Kalmanovým filtrem	29
1.2.2 Otsu metoda v kombinaci s deformačním tvarovým modelem a filtrací	29
1.2.3 Shape Regression Machine	31
2 Dynamická Echokardiografie	33
2.1 Formování echokardiografického obrazu	33
2.1.1 Módy Echokardiografie	33
2.1.2 Piezoelektrická sonda	36
3 Klinické využití Echokardiografie	38

3.1	Patologické nálezy v Echokardiografii.....	38
3.2	Srdeční osy a pohledy u vyšetření srdce	39
3.2.1	Parasternální vyšetření	40
3.2.2	Apikální vyšetření	40
3.2.3	Subkostální vyšetření	40
3.2.4	Suprasternální vyšetření	40
	PRAKTICKÁ ČÁST.....	41
4	Struktura obrazových dat	42
4.1	Typy šumů.....	43
4.1.1	Speckle noise.....	43
4.1.2	Gaussův šum	45
4.1.3	Šum Salt and Pepper	46
4.2	Měření míry degradace obrazových dat	47
4.2.1	DICE koeficient.....	47
4.2.2	Strukturální podobnost (SSIM)	47
4.2.3	Střední kvadratická chyba (MSE)	49
4.2.4	Korelace (CORR).....	50
5	Metoda aktivních kontur	51
5.1	Hranové, parametrické aktivní kontury.....	51
5.2	Geometrické aktivní kontury se statistickým rozložením pixelů – level-set.....	51
6	Implementace algoritmu geometrických aktivních kontur.....	54
6.1	Načtení snímku.....	54
6.2	Předzpracování obrazu	56
6.3	Návrh segmentační procedury pro genezi modelu srdečních struktur	58
6.4	Extrakce segmentovaného modelu.....	64

6.5	Měření parametrů v extrahovaném modelu.....	65
7	Testování algoritmu aktivních kontur	69
7.1	Binární extrakce segmentovaného srdečního modelu	74
7.1.1	Hodnocení DICE koeficientu	76
7.2	Konturovaná extrakce srdečního modelu	79
7.2.1	Hodnocení SSIM	81
7.2.2	Hodnocení MSE	85
7.2.3	Hodnocení CORR	89
7.3	Dynamické sledování srdečních parametrů.....	94
7.4	Sledování srdečních struktur v patologických nálezech.....	98
7.4.1	Mírná dilatace síní	98
7.4.2	Fibrilace síní	100
7.4.3	Dilatace levostranných oddílů	102
8	Graficko-uživatelské rozhraní pro modelování zájmových struktur z Echokardiografie.....	103
8.1	Výběr jednoho snímku	105
8.2	Výběr datové sady snímků	110
9	Závěr	112
10	Zdroje	113
	Seznam příloh.....	115
	Příloha I.....	115
	Příloha A:	115
	Příloha B:	115
	Samostatná příloha II	115

Seznam použitých zkratk

AAM

Active Appearance model (Aktivní vzhledový model)

ASM

Active Shape Model (Aktivní tvarový model)

BFD

Boosted Feature Regression

BFR

Boosted Feature Regression

COR

Korelace

FMED

Fuzzy vícestupňová detekce hran

GUI

Graficko-uživatelské rozhraní

LK

Levá komora

MSE

Střední kvadratická chyba

PK

Pravá komora

PSNR

Váhový poměr signálu k šumu

RMSD

Střední kvadratická odchylka

ROI

Region of Interest (Oblast zájmu)

SRM

Shape Regression Machine

SSIM

Strukturální podobnost

SW

Software

UZV

Ultrazvuk, ultrazvukový

Seznam obrázků

Obrázek 1: Vlevo: počáteční snímek, vpravo: inicializační maska [5].	23
Obrázek 2: Vlevo: výsledek přizpůsobující se po 100 iteracích, vpravo: výsledek po 1000 iteracích [5].	24
Obrázek 3: Segmentace pomocí metody aktivních kontur [4].	26
Obrázek 4: Referenční snímek (vlevo), prahování (vpravo) [5].	27
Obrázek 5: Zleva: Gaussova metoda s medianovým filtrem, Laplacianova metoda s mediánovým filtrem, konečný výsledek [3].	28
Obrázek 6: Průběh křivky algoritmu v čase [8].	29
Obrázek 7: Zleva: počáteční data, AM filtr 2D, AMS filtr 2D, AMS filtr 3D, lokální entropie 2D [9].	30
Obrázek 8: Separovaná segmentovaná rovina [9].	31
Obrázek 9: Oblasti zájmu pomocí SRM [5].	32
Obrázek 10: Tréninková množina snímků z databáze postupně trénující regresor [5].	32
Obrázek 11: B-mód ultrazvuku s vysvětlením srdečních struktur. Upraveno z [10].	34
Obrázek 12: B-mód se zainteresovaným M-módem. (a) parasternální pohled. (b) zobrazení M-módu zelené vodorovné linie v (a). (c) zobrazení módu modré linie v (a). Převzato z [10].	35
Obrázek 13: Dopplerovské zobrazení ve 2D [10].	36
Obrázek 14: Snímek z echokardiografického vyšetření srdce pomocí sektorové sondy, převzato z [12].	37
Obrázek 15: Vzhled sektorové sondy, upraveno z [11].	37
Obrázek 16: Znázornění srdečních os [19].	39
Obrázek 17: Obrzy z datové sady I.	42
Obrázek 18: Obrázky z datové sady II.	42
Obrázek 19: Obrázky z datové sady III.	42
Obrázek 20: Příklad echokardiografického snímku s rozpoznáním srdečních struktur [upraveno z 10].	43

Obrázek 21: Zobrazení echokardiografických dat zatížených umělým speckle šumem o rozptylu 0,04.	44
Obrázek 22: Degradace ultrazvukového obrazu Gaussovým šumem pro užití k testování. Rozptyl všech šumů: $v=0,01$. Nahoře vlevo: $m=0,01$, vpravo: $m=0,1$, dole: $m=0,02$	45
Obrázek 23: Postupná degradace ultrazvukového obrazu šumem Salt and Pepper pro užití k testování. Nahoře vlevo $d=0,001$, vpravo: $d=0,01$, dole: $0,02$	46
Obrázek 24: Ideální závislosti SSIM na rostoucích parametrech Gaussova šumu	48
Obrázek 25: Ideální závislosti MSE na rostoucích parametrech Gaussova šumu	49
Obrázek 26: Ideální závislosti CORR na rostoucích parametrech Gaussova šumu	50
Obrázek 27: Rozdělení inicializační oblasti kontury	52
Obrázek 28: Vývojový diagram regionálních aktivních kontur pomocí level-set	53
Obrázek 29: Vývojový diagram procesu nalezení srdečních struktur	54
Obrázek 30: Načtení nativního snímku	55
Obrázek 31: Zobrazení všech nativním snímku datové sady I	55
Obrázek 32: Vývojový diagram předzpracování obrazu	56
Obrázek 33: Graf znázorňující jasovou transformaci k předzpracování obrazu	56
Obrázek 34: Předzpracovaný obraz	57
Obrázek 35: Zobrazení všech předzpracovaných snímku datové sady I	58
Obrázek 36: Diagram segmentačního algoritmu dle funkcí	60
Obrázek 37: Neefektivní nastavení aktivní kontury. Vlevo: malý počet iterací – 300, časový krok – 0,005 s, jádro o velikosti 10. Vpravo: velký počet iterací – 2500, časový krok - 0,1 s, jádro o velikosti 40.	61
Obrázek 38: Znázorněný vývoj kontury po iteracích	61
Obrázek 39: Zobrazení všech segmentovaných předzpracovaných snímku datové sady I	62
Obrázek 40: Zobrazení ROI segmentovaných oblastí datové sady I	63
Obrázek 41: Ukázky segmentovaných předzpracovaných snímků datové sady II a III	63

Obrázek 42: Ukázka arteficiálního barevného mapování energetické kontury prvního snímku (datová sada I).	64
Obrázek 43: Zobrazení kontury na základě monochromatického obrazového spektra prvního snímku (datová sada I).	64
Obrázek 44: Vlevo: Zobrazení binárního modelu aktivních kontur prvního snímku (datová sada I), Vpravo: Specifikace měřených parametrů.	65
Obrázek 45: Zobrazení segmentovaných modelů v binární formě datové sady I.	66
Obrázek 46: Nativní echokardiografická data ovlivněna syntetickým Gaussovým šumem s deterministicky přidanými parametry a jejich postupným zvyšováním.	70
Obrázek 47: Nativní echokardiografický snímek ovlivněn syntetickým speckle šumem s deterministicky přidanými parametry.	70
Obrázek 48: Nativní echokardiografická data ovlivněna syntetickým Salt and Pepper šumem s deterministicky přidanými parametry a jejich postupným zvyšováním.	71
Obrázek 49: Zobrazení segmentovaných částí ovlivněných syntetickým Gaussovým šumem s postupně zvyšujícími se parametry.	72
Obrázek 50: Segmentovaný echokardiografický snímek ovlivněn syntetickým speckle šumem s deterministicky přidanými parametry.	72
Obrázek 51: Zobrazení segmentovaných částí ovlivněných syntetickým Salt and Pepper šumem s postupně zvyšujícími se parametry.	73
Obrázek 52: Extrahované binární modely echokardiografických dat s deterministicky přidaným Gaussovým šumem s postupně zvyšujícími se parametry pro výpočet DICE koeficientu.	74
Obrázek 53: Extrahované binární modely echokardiografických dat s deterministicky přidaným Salt and Pepper šumem s postupně zvyšujícími se parametry pro výpočet DICE koeficientu.	75
Obrázek 54: Extrahovaný binární model echokardiografického snímku s deterministicky přidaným speckle šumem pro výpočet DICE koeficientu.	75
Obrázek 55: DICE koeficient v závislosti na parametrech Gaussova šumu u všech obrazů v testovací databázi.	77
Obrázek 56: DICE koeficient v závislosti na parametrech Salt and Pepper šumu u všech obrazů v testovací databázi.	78
Obrázek 57: Extrahované konturované modely echokardiografických dat s deterministicky přidaným Gaussovým šumem s postupně zvyšujícími se parametry pro výpočet SSIM, CORR a MSE.	79

Obrázek 58: Extrahované konturované modely echokardiografických dat s deterministicky přídáním Salt and Pepper šumem s postupně zvyšujícími se parametry pro výpočet SSIM, CORR a MSE.	80
Obrázek 59: Extrahovaný konturovaný model echokardiografického snímku s deterministicky přídáním speckle šumem pro výpočet SSIM, MSE, CORR.	80
Obrázek 60: Strukturální podobnosti (SSIM) všech obrazů šumové databáze v závislosti na parametrech Gaussova šumu.	83
Obrázek 61: Strukturální podobnosti (SSIM) všech obrazů šumové databáze v závislosti na parametrech šumu Salt and Pepper.	83
Obrázek 62: Průměry strukturálních podobností jednotlivých obrazů v závislosti na parametrech šumů.	84
Obrázek 63: Mediány strukturálních podobností jednotlivých obrazů v závislosti na parametrech šumů.	84
Obrázek 64: Rozptyly strukturálních podobností jednotlivých obrazů v závislosti na parametrech šumů.	85
Obrázek 65: Střední kvadratická chyba (MSE) všech obrazů šumové databáze v závislosti na parametrech Gaussova šumu.	87
Obrázek 66: Střední kvadratická chyba (MSE) všech obrazů šumové databáze v závislosti na parametrech šumu Salt and Pepper.	87
Obrázek 67: Průměry středních kvadratických chyb jednotlivých obrazů v závislosti na parametrech šumů.	88
Obrázek 68: Mediány středních kvadratických chyb jednotlivých obrazů v závislosti na parametrech šumů.	88
Obrázek 69: Rozptyly středních kvadratických chyb jednotlivých obrazů v závislosti na parametrech šumů.	89
Obrázek 70: Korelace (CORR) všech obrazů šumové databáze v závislosti na parametrech Gaussova šumu.	91
Obrázek 71: Korelace (CORR) všech obrazů šumové databáze v závislosti na parametrech šumu Salt and Pepper.	91
Obrázek 72: Průměry korelací jednotlivých obrazů v závislosti na parametrech šumů.	92
Obrázek 73: Mediány korelací jednotlivých obrazů v závislosti na parametrech šumů.	92
Obrázek 74: Rozptyly korelací jednotlivých obrazů v závislosti na parametrech šumů.	93

Obrázek 75: Nativní dynamická sada snímků.....	94
Obrázek 76: Segmentované snímky aktivních kontur v dynamickém režimu. Iterace – 1800, časový krok 0,005 s, velikost jádra 10.....	95
Obrázek 77: Sekvence binárních modelů aktivních kontur dynamického cyklu.	96
Obrázek 78: Nahoře: Nativní snímek pacienta s mírnou dilatací síní I, dole: předzpracované segmentované snímky srdečních struktur.	98
Obrázek 79: Nahoře: nativní snímek u pacienta s mírnou dilatací síní II, dole: předzpracované segmentované snímky srdečních struktur.	99
Obrázek 80: Nahoře: nativní snímek u pacienta s fibrilací síní I, dole: předzpracované segmentované srdeční struktury.....	100
Obrázek 81: Nahoře: nativní snímek u pacienta s fibrilací síní II, dole: předzpracované segmentované srdeční struktury.....	101
Obrázek 82: Vlevo: Nativní data u jednostranných dilatací, vpravo: předzpracované segmentace srdečních struktur.	102
Obrázek 83: Vývojový diagram graficko-uživatelského rozhraní algoritmu pro segmentaci srdečních struktur.	103
Obrázek 84: Úvodní okno GUI pro výběr segmentovaných oblastí.	104
Obrázek 85: GUI výběr jednoho snímku.	105
Obrázek 86: GUI pro výběr jednoho snímku, Výběr snímku.	106
Obrázek 87: GUI pro výběr jednoho snímku, Předzpracování obrazu.	107
Obrázek 88: GUI pro výběr jednoho snímku, Vyber oblast.....	108
Obrázek 89: GUI pro výběr jednoho snímku, Měření parametrů.	109
Obrázek 90: GUI pro výběr datasetu snímků.....	110
Obrázek 91: Inicializační okno pro všechny obrazy.	110
Obrázek 92: GUI pro výběr datasetu snímku, Vyber oblast zájmu.....	111

Seznam tabulek

Tabulka 1: Porovnání kvality filtrů dle RMSD a PSNR [3].	28
Tabulka 2: Fyziologické hodnoty srdečních struktur [18].	38
Tabulka 3: Sledované parametry u echokardiografického vyšetření [19, 20].	38
Tabulka 4: Specifikace a parametry aktivní kontury.	59
Tabulka 5: Změřené a přepočítané parametry modelu levé srdeční komory ze snímků z datové sady I.	67
Tabulka 6: Porovnání změřených a fyziologických parametrů LS srdeční.	67
Tabulka 7: Změřené a přepočítané parametry modelu pravé srdeční komory ze snímků z datové sady II.	68
Tabulka 8: Porovnání změřených a fyziologických parametrů PS srdeční.	68
Tabulka 9: Zobrazení kompletní testované struktury Im s parametry šumů.	69
Tabulka 10: Hodnoty DICE koeficientu pro vybrané parametry šumů z databáze I.	76
Tabulka 11: Intervaly hodnot DICE koeficientů pro jednotlivé parametry šumu.	77
Tabulka 12: Hodnoty SSIM pro vybrané parametry šumů z databáze I.	81
Tabulka 13: Intervaly hodnot SSIM pro jednotlivé parametry šumu.	82
Tabulka 14: Hodnoty MSE pro vybrané parametry šumů z databáze I.	85
Tabulka 15: Intervaly hodnot MSE pro jednotlivé parametry šumu.	86
Tabulka 16: Hodnoty CORR pro vybrané parametry šumů z databáze I.	89
Tabulka 17: Intervaly hodnot CORR pro jednotlivé parametry šumu.	90
Tabulka 18: Měřené parametry v PS srdeční pro dynamickou sadu snímků.	97

Seznam rovnic

Rovnice (1) Výpočet DICE koeficientu	47
Rovnice (2) Výpočet složky jasů pro parametr SSIM.....	47
Rovnice (3) Výpočet složky kontrastu pro parametr SSIM	47
Rovnice (4) Výpočet složky struktury pro parametr SSIM.....	47
Rovnice (5) Kompletní výpočet parametru SSIM.....	48
Rovnice (6) Výpočet parametru MSE	49
Rovnice (7) Výpočet kernelovy funkce v jedné iteraci aktivních geometrických kontur	52
Rovnice (8) Definice filtru pro zvýraznění hran	57

Úvod

Echokardiografické vyšetření v kardiologii je důležitou součástí diagnostického procesu při posuzování rozměrů, parametrů a patologií srdce v dynamickém režimu. Diplomová práce se bude zabývat nalezením vhodného segmentačního algoritmu pro detekci srdečních komor a parametrů v závislosti na kvalitě nativních dat.

Druh segmentačního algoritmu bude navrhován a testován na základě řešerše získané z odborných publikovaných článků z problematiky echokardiografických dat. Dílčí částí segmentačního algoritmu bude data vhodně předzpracovat pomocí filtrací a jasových transformací, jelikož získaná data z Echokardiografie jsou velice specifická a různorodá u každého jedince. Po správném nastavení segmentačního algoritmu a akceptovaných výsledcích se algoritmus bude testovat na různou kvalitu dat ovlivněných jak přirozeným šumem vzniklým při vyšetření, tak šumem získaným z šumových generátorů. Na základě testování se statisticky určí účinnost algoritmu s nalezením jeho zlatého středu v robustnosti pro echokardiografická data.

Konečným výsledkem diplomové práce bude vytvořit graficko-uživatelské rozhraní pro poloautomatickou detekci srdečních komor a jejich parametrů. Stanoví se nejefektivnější segmentační algoritmus dle testování a vyhodnocení statistických parametrů v účinnosti detekce srdečních komor a jeho parametrů v Echokardiografii. V budoucnu usnadní klinikům interpretaci vyšetření a objektivnější posouzení srdce u všech vyšetřovaných pacientů touto metodou.

TEORETICKÁ ČÁST

Dílčí částí teorie je vytvořená rešerše s vědeckých publikací, kde je popsáno několik segmentačních procedur souvisejících s echokardiografickými snímky a jejich řešení pomocí navržených algoritmů. Jedná se o kombinace jednoduchých segmentačních metod s nádstavbovými funkcemi. Rešerší vyvstaly závěry pro výběr segmentačního algoritmu pro tuto práci.

Dále je obsažena přehledná sumarizace vyšetření dynamické Echokardiografie v klinickém i technickém pojetí a porozumění srdečním strukturám v rámci techniky ultrazvukového vyšetření s vymezením fyziologických parametrů srdečních síní a komor.

1 Rešerše: Segmentace v echokardiografických snímcích

Předmětem rešerše bylo sumarizovat segmentační procedury v Echokardiografii v komplexním využití s uvážením parametrů poskytnutých dat. Stěžejní částí se stala sumarizace segmentačních procedur z vědeckých článků a jejich aplikace v dynamické Echokardiografii. Všechny poznatky z čerpaných publikací prokázaly významný posun a užitečnost ve zpracování obrazu, jak pro klinické, tak pro technické obory. Hodnotí přehled segmentačních způsobů se současnými přístupy a možnostmi, od kterých se na začátku zpracování obrazu odvíjí výběr segmentačního modelu s vymezením oblasti zájmu ROI (Region of Interest), a zároveň vyhodnocuje účinnost při daných výchozích počátečních podmínkách, což znamená kvalitu a strukturu dat získaných při Echokardiografii.

1.1 Základní segmentační metody a jejich principy

Užití segmentačních algoritmů v echokardiografii je velice rozsáhlý. Komplexně jsou níže uvedeny echokardiální segmentační metody, které se efektivně užívají poloautomatickou formou. Znalostí testovaných snímků dokážeme tyto metody využít a zkombinovat pro dosažení žádoucích výsledků v segmentaci endokardu. Existuje velmi malé množství výzkumů, které se zabývaly segmentací myokardu vzhledem i k jeho špatné rozpoznatelnosti v echokardiografickém snímku [1, 6, 2, 5].

Většina pozornosti při Echokardiografii se přikládá oblasti, kdy krev v srdečních komorách přechází v endokard. V ultrazvukových snímcích rozpoznáváme vzhled levé komory jako největší tmavou oblast, která reprezentuje krev uzavřenou endokardem, myokardem a epikardem. Obraz je reprezentován body v odstínech šedé, které jsou uspořádány vedle sebe, tudíž tvoří obraz jako celek [1].

Metoda aktivních kontur je nejvíce vyzdvižovanou mezi výzkumníky, avšak metoda level-set lépe zvládá určité topologie v obraze. Obě se prolínají a kombinují s řadou dalších diskutovaných metod, které mohou být vhodnější pro určité typy získaných klinických snímků [1, 6, 2, 5].

1.1.1 Level-Set metoda

První segmentační algoritmus můžeme popsat s cílem zkvalitnění obrysů kontur kolem komor. Jedná se o geometrický deformovatelný model. Metoda level-set dokáže zvýšit komplexnost regionů a jeho hranic na základě vytvoření nulové hladiny řezem v objektu, která představuje křivku, podle níž se počítá výška k okolním bodům. Metoda se postupně adaptuje vzhledem k metrikám křivosti a obrazovým gradientům. Tvar křivky však není měněn přímo, nýbrž pomocí funkce level-set [1].

Hlavní myšlenkou je reprezentovat křivky nebo plochy jako nulovou množinu vyššího rozměrového povrchu. Metoda je velice všestranná, přesná a robustní, jelikož řeší širokou škálu komplexních problémů a není třeba parametrizovat objekt. Pomáhá vyřešit problém s nalezením hranových bodů.


Díky této funkci se postupně vytvoří segmentační algoritmus, který se nejlépe přizpůsobuje komplexnímu objektu, a proto je stěžejní znalost tvaru objektu, což při nejasných jasových strukturách v oblasti srdce může být problémem. Klíčovým u této metody se tedy stává předzpracování obrazu s účelem zkvalitnit data [1].

Implementace level-set metody


1. Převod obrazu RGB do monochromatického formátu
2. Nastavení počátečních podmínek podle požadované oblasti.
3. Program poté spustí a generuje uzavřený polygon= inicializační maska.
4. Pomocí Euklidovy vzdálenosti se změří distanční transformace, která přiřadí hodnotu každému pixelu. Hodnota představuje minimální vzdálenost pixelu na nejbližší hranový bod objektu.
5. Transformace zároveň přiřadí hodnotu $+$ pixelům do objektu nepatřících a hodnotu $-$ pixelům uvnitř objektu.
6. Nastavení počtu iterací.
7. Iterativní výpočet derivací [5].

Evoluce algoritmu je řízen diferenciální rovnicí. Topologické změny v okrajích objektu (hranicích) je lépe řešena metodou level-set než aktivními konturami [6].

Lze pozorovat, že algoritmus pracuje trvale po celou dobu a vývoj kontury se udržuje uvnitř diagnosticky relevantní oblasti (Obrázek 1, Obrázek 2). Když se odhadne tvar levé komory, lze snadno vypočítat změny v oblasti levé komory během srdeční systoly a diastoly [5].



Obrázek 1: Vlevo: počáteční snímek, vpravo: inicializační maska [5].



Obrázek 2: Vlevo: výsledek přizpůsobující se po 100 iteracích, vpravo: výsledek po 1000 iteracích [5].

Jedním z přístupů při detekci endokardiální hranice je využití průměrné energie založené na gradientu průměrné intenzity v rychlosti namísto běžného použití gradientu lokální intenzity jasu. Level-set metoda se může uplatnit společně s hranovou detekcí a regionální segmentací. Inicializace se provádí pomocí Gaussova filtru s následným nastavením hran a regionů [6].

1.1.2 Metoda aktivních kontur

Metodu aktivních kontur lze vnímat jako parametrický model. Aktivní kontura je obdobou level-set metody, ale její výhoda spočívá ve snížení požadavků na počáteční inicializační konturu, při které nemusíme důkladně znát vlastnosti objektu. Aktivní kontury nepotřebují přesné stanovení funkce v počátku, podle níž se křivka dále v objektu adaptuje [1].

Počítačem generované křivky, které se pohybují uvnitř obrazu a nacházejí tak hranice objektů pod vlivem vnitřních a vnějších sil. Nejprve se kontura umístí do ROI a během iteračního procesu je přitahována pomocí vnitřních a vnějších sil k cíli. Síly kontrolují umístění kontury v obraze a vytváří energetickou funkci. Minimalizace energetické funkce (integrál) představuje celkovou energii aktivního obrysu. Vnitřní síly jsou odpovědné za hladkost a vnější za síly vedoucí obrysy. Tato technika obsahuje klíčové koncepty založené na regionech a na bázi hran. Je to poněkud složitější procedura z hlediska výpočetní náročnosti, ale vylepšuje hranice objektů [5].

Rozšířeně se užívá právě u sledování echokardiografických sekvencí obrazu. Počáteční obrys komory ve snímku je počátečním obrysem pro každý snímek dále v pořadí [6].

Navrhovaný algoritmus se skládá ze tří základních modulů:

1. Výpočet návratnosti pomocí Hough transformace (nalezení nepřesných objektů),
2. anizotropní difuze šumu obrazu (SRAD),
3. segmentace obrazu metody aktivních kontur bez hran [6].

1.1.2.1 Aktivní tvarový model (ASM) & Aktivní vzhledový model (AAM)

Tyto principy potřebují ke své inicializaci velké množství tréninkových snímků, a navíc předpokládají normální rozložení dat, což v případě nekonzistentní kvality jednotlivých vyšetření na pacientech není přijatelné. Modely se proto dají využít při velmi kvalitním předzpracování obrazu a v kombinaci s pomocnými morfologickými operacemi [1].

ASM spočívá v ručním stanovení sady bodů v obraze, a tak dochází k určení lokace hledaného objektu. Body hledají nejlepší shodu lokálních vlastností objektu. Při korespondujících nalezeních jednotlivých vlastností bodů, se vypočítají jednotlivé euklidovské vzdálenosti mezi dvěma sousedními body a objekt se proloží tvarem (jeho obrysem) [2].

Omezením aktivních obrysových metod je, že uživatel potřebuje inicializovat hrubý obrys hranic. To může vést ke změně výsledků v závislosti na zkušenostech uživatelů. Aktivní tvarové a vzhledové modely (ASM, AAM) definují aktivní pohybový model ručně definovaných bodů v objektu [6].


1.1.2.2 Boosted Feature Detection (BFD) & Boosted Feature Regression (BFR)

Užívá původního algoritmu AAM s rozšířenými funkcemi. Hlavním cílem je naučit algoritmus rozlišit žádané obrazové body objektu X a okolní s podobnými vlastnostmi, které však do objektu nepatří Y. Cílem je zvolit pozitivní skupinu pixelů X a předpovídat negativní do objektu nepatřící Y. Každému z obrazových bodů se připisuje váha dle hodnoty jeho významnosti. Stanovená funkce pro objekt je pak trénována vypočtením vážených průměrů bodů do objektu nepatřících Y. Chyba každé funkce je pak vážený součet rozdílů čtverců bodů Y a středních hodnot vybraných žádaných bodů X [2].

BFR navazuje na algoritmus BFD ale využívá regrese, která se naučí vztah mezi posunem skutečné umístění funkce a texturním vzhledem místního sousedství kolem každého bodu. Využívá tedy stejného klasifikačního tréninku jako BFD, ale označuje posuny od stanovené žádané funkce pro objekt. Regresní trénink proto využívá veškeré dostupné trénovací údaje, zatímco klasifikační trénink odstraňuje některé nejednoznačné body [2].

BFR je však několikrát rychlejší než BFD v závislosti na výkonnosti procesu a použitého programovacího jazyka. Zároveň právě regresní metoda je více robustnější při horším rozlišení obrazu, protože jak už vyplynulo, bere v potaz širší spektrum chyb díky své regresi [2].

Užívá se také metoda aktivních kontur (Obrázek 3) s použitím genetického algoritmu. Energie aktivních kontur je minimalizována použitím právě genetického algoritmu. Předběžná úprava obrazu byla navržena pro automatickou inicializaci obrysu. Pro algoritmus aktivního obrysu používali gradient intenzity obrazu jako přitahující sílu. Sledování je také vyhlazeno použitím časové kontinuity v rámci rámců, které omezují pohyb mezi dvěma po sobě jdoucími snímky [6].



Obrázek 3: Segmentace pomocí metody aktivních kontur [4].

1.1.3 Metoda deformovaných šablon

Funkci se předloží vzor, podle něhož se obraz snaží přizpůsobit. Metoda deformovaných šablon bývá výchozí pro snímky, ve kterých máme kvalitně zobrazeny srdeční komory a jsou méně poznamenány šumem. Poté dokážeme určit šablonu schopnou se přizpůsobit srdečním komorám, a tak je vymezit [1].

1.1.4 Metoda databáze


Tato segmentační třída je velice složitá na nalezení hledaného objektu. Specifická je svými požadavky na tvar a tréninkové snímky k určení srdečních komor, kde je potřeba důkladně znát parametry objektu, což z hlediska variability srdečních komor u jednotlivých pacientů bývá obtížné [1].

1.1.5 Detekce hran

Metoda řeší segmentaci vyhledáváním hran v obraze nebo pixelů mezi regiony, kde dochází k prudkým změnám jasu, a tím ke změně struktury objektu. Úspěšnost je velice úzce spjata s kontrastem snímků. Segmentace nefunguje v obraze se špatně definovanými hranami [5].

1.1.6 Prahování

Prahování (Obrázek 4) spočívá v určení prahové hodnoty intenzity pixelu, od které budeme pixely rozřazovat dle intenzit jejich jasu. Na začátku je nutné si zobrazit histogram intenzit pixelů pro správné nastavení prahu. Můžeme také vytvořit větší množství prahů a pixely tak rozřazovat do několika regionů při nesourodých datech. Významově se podobá také metoda shlukování, kdy definujeme konečnou skupinu kategorií pro klasifikaci pixelů. Neužívá se fáze výcviku, ale klastry (shluky pixelů), které učí pomocí dostupných dat a klasifikují tak konečné skupiny (regiony) pixelů [5].



Obrázek 4: Referenční snímek (vlevo), prahování (vpravo) [5].

1.1.7 Neuronové sítě

Algoritmy mohou být založené na fuzzy detekci hran srdečních komor. Následně jsou epikardiální a endokardiální okrajové hraniční body prohledávány na radiálních liniích pocházejících ze středu pomocí fuzzy víceúrovňové detekce hran (FMED). Tyto okrajové body jsou vyhlazeny prostorově a časově pomocí kubické techniky B-Spline. Na redukci šumu se používá Wavelet filtr. Jiní autoři použili prostorově časový přístup založený na buněčné neuronové síti, aby našli a sledovali hranici endokardu [6].

1.2 Kombinované segmentace

Ve velké míře dochází ke vzájemné kombinaci algoritmů se základních segmentací. Žádoucím by bylo dostat kvalitní data na začátku zpracování obrazu, avšak nikdy nejsou ideálně kvalitní a rozpoznatelné při hledání anatomických struktur. Hlavní nevýhodou klinických vyšetření diagnostických metod je omezený softwareový balíček stávajících zařízení [3].

U segmentace nesmíme opomenout řadu doprovázejících operací, bez kterých by jinak nebyla účinná. Jedná se o filtraci obrazu, zvýšení kontrastu se zvýrazněním hran a redukcí šumu, výpočtu ROI, použití morfologických operací.

Pro správnou funkcionalitu výše popsaných segmentačních algoritmů je potřeba se důkladně zaměřit na předzpracování obrazu, což bývá klíčové pro aplikaci a úsudek, která segmentační metoda by byla na požadované snímky nejefektivnější. Je nutno zvýraznit a omezit veškeré rušivé elementy v obraze, což může být například šum (*tzv. speckle noise*) způsobený nerovnoměrným tlakem sondy na lidskou tkáň, neefektivně nastavená frekvence ultrazvukové sondy, nevhodně nastavené parametry ultrazvukového přístroje pro konkrétní vyšetření, neschopnost důkladně zobrazit struktury z hlediska vyššího množství tukové tkáně pacienta a tak dále. Všechny tyto problémy se musí například filtrací a změnou jasu eliminovat, potlačit, aby vybraný segmentační algoritmus nebo jejich kombinace byly schopny žádané struktury separovat a najít.

Stávající algoritmy pro detekci hranic srdečních komor, založené na segmentaci struktury a morfologických přeměnách nezohledňují úhel sklonu srdcových komor a diskontinuální obrysy.

Algoritmy používající aktivní kontury vyžadují počáteční aproximaci ohraničení komory, která je iterativně ručně přizpůsobena skutečnému okraji. Ale kvůli vlastnostem každého okraje je tak obtížné nalézt obrysové parametry, které poskytují přijatelné výsledky [3].

Segmentační algoritmy stojí především na dvou základních vlastnostech:

1. Diskontinuita: Přístupy založené na hranové detekci, které hledají náhlou změnu intenzity v obraze.
2. Podobnost: Regionální metody segmentace podle nastavených kritérií pro jednotlivé regiony [7].

Autoři analýz testovali účinnost Gaussovy metody s mediánovým filtrem a Laplacianovy metody s mediánovým filtrem. Níže (Obrázek 5) jsou zobrazeny výsledky segmentací.



Obrázek 5: Zleva: Gaussova metoda s medianovým filtrem, Laplacianova metoda s mediánovým filtrem, konečný výsledek [3].

Digitální obrazový šum je artefakt prezentovaný jako náhodná odchylka jasu nebo barvy od původních hodnot. Zašumnělé pixely mohou být chybně klasifikovány jako okrajové. Existuje řada filtrů, která se dá použít pro eliminaci speckle noise. Jednotlivé filtry (Tabulka 1) jsou porovnávány níže. Jako nejefektivnější se jeví Ramponiho filtr, který má minimální RMSD (střední kvadratickou odchylku) a maximální PSNR (váhový poměr signálu k šumu). Samozřejmě záleží na datasetu snímků, a proto v praxi by se měly testovat všechny dostupné filtry a zvážit jejich možnosti [3].

Tabulka 1: Porovnání kvality filtrů dle RMSD a PSNR [3].

Typ filtru	RMSD	PSNR [dB]
Kuan	8	14
Mediánový	12	13
Sigma	10	15
Ramponiho	5	16

Vědečtí pracovníci dále představili poloautomatickou metodu, která používala matematickou morfologii k segmentaci endokardu v echokardiogramech. Morfologický otevírací filtr byl aplikován na kompozitní rám (průměr všech rámců), který odstranil intenzitu vysokých intenzit v obraze. Výsledný obraz byl potom odečten od původní informace o zadržovací hraně částečně korigované pro variaci stupně šedi, následovanou uzavřením stupně šedi a binární dilatací [7].


Mimo jiné výzkumy vědci také provedli metodu extrakce vlastností ultrazvukových obrazů. Zpočátku rozlišili obraz pro vytvoření kompozitního snímku z dvaceti sekvenčních obrazů a následně odečetli kompozitní a jednotlivé snímky. Pomocí empirického prahování úrovně šedé získali binární obraz. Výstup zdůraznil špatné hrany, ale také vnitřní hranice pláště objektu. Metoda, pomocí které se segmentace provedla, je založena na technice aktivních obrysů. Využívá konceptu kombinace více modelů trajektorií pro sledování jediného cíle v náhodně rozloženém prostředí. Křivka se vyvíjí z počáteční polohy směrem k hranici a minimalizací energetické funkce, která se skládá z vnitřní a vnější energie. Vnitřní síly jsou odpovědné za hladkost a vnější za vedoucí obrysy [7].

1.2.1 Aktivní tvarový model v kombinaci s Kalmanovým filtrem

Segmentace se provedla po sekvencích pomocí rozšířeného Kalmanova filtru, který rekurzivně předvídá a získává parametry srdce z 3D ASM modelu v reálném čase. Kalmanův filtr využívá aktuálně naměřených dat a srovnává je s modelem vytvořeným aktivním tvarovým modelem a zároveň uvažuje i minulý stav systému. ASM model se parametry naučil sledováním fyziologických snímků, a poté pouze upravuje parametry získané z Kalmanova filtru. Detekce hran je založena na normálních měřených posunech, které se spočítaly z radiálních vzdáleností mezi zjištěnými okrajovými body [8].

Vytvoření aktivního tvarového modelu vyžaduje korespondenci mezi dvojicí bodů v objektu u různých pacientů. Algoritmus klasifikuje reparametrizovanou křivku znázorňující převedení triangulovaných výcvikových tvarů srdečních komor do jednodušších čtyřúhelníků (Obrázek 6) [8].

Pro hodnocení v celkové klinické použitelnosti je potřeba algoritmus testovat na větší populaci s poskytnutím většího množství patologií ve tréninkovém setu snímků pro ASM model [8].



Obrázek 6: Průběh křivky algoritmu v čase [8].

1.2.2 Otsu metoda v kombinaci s deformačním tvarovým modelem a filtrací

Stěžejním se stalo 2D a 3D adaptivní filtrování pro snížení šumu a optimalizace rozdílu mezi krví a myokardem při zachování ostrosti hran mezi různými strukturami srdce. Obrazy obsahují vysokou úroveň multiplikačního šumu a neizotropní charakteristiky zpětného rozptylu endokardu vyvolávají nízkou úroveň ozvěny při podélném dopadu ultrazvuku vzhledem k orientaci vláken [9].

Testování kvality filtrů

Rozdíl mezi procentuálním zastoupení krve a myokardu byl testován na Wilcoxonově souhrnném součtovém testu (test shody dat) na všech datových množinách. Jako druhé opatření pro kvalitu různých filtračních metod byla stanovena oblast pod křivkou pro ručně segmentované krevní oblasti. Oblast krve byla potom porovnána s tkání, protože to odpovídá endokardiálnímu obrysu [9].

Zařazeny byly způsoby adaptivního filtrování pomocí 2D a 3D filtrovacích jader: filtrování Adaptive Mean (2D), Adaptive Mean Squares (2D a 3D) a kromě adaptivního filtrování byla použita ještě lokální entropie (Obrázek 7). Stupeň vyhlazení byl automaticky řízen homogenitou oblasti, ve které byl filtr aplikován. Oblasti, které obsahují okraj, nejsou homogenní, a proto budou méně vyhlazené než homogenní oblasti. Strategie zaručuje zachování ostrosti okrajů různých struktur. Kvalita filtru byla měřena porovnáváním, a poté se aplikovalo automatické prahování, aby se vytvořila hraniční kontura hledaného endokardu, což nám umožní vizualizovat abnormality v anatomii srdce [9].

Aplikováno bylo prostorové filtrování, aby se snížily odrazy a současně se zvýšil kontrast mezi krví a myokardem a zachovala se ostrost okrajů. Spektrální charakteristiky jsou závislé na hloubce v důsledku difrakce paprsku a zaostření, stejně jako z důvodu útlumu [9].



Obrázek 7: Zleva: počáteční data, AM filtr 2D, AMS filtr 2D, AMS filtr 3D, lokální entropie 2D [9].

V prvním kroku vedly filtrační procedury ke snížení šumu a zachování ostrosti okrajů. Nehomogenní oblasti tkání byly adaptivními postupy téměř neovlivněny, zatímco entropická metoda je nepatrně vyhladila. Statistické testování filtrací odhalilo, že kvalita dat výrazně vzrostla. Nicméně změny byly nepatrné ve srovnání mezi všemi filtry [9].


Implementace algoritmů

Rekurzivně se implementovala Otsu metoda na data pro nalezení optimálního prahu mezi krví a tkání. Optimální práh byl pak použit pro vytvoření binárního obrazu, ve které je krev oddělena od tkáně. Výsledný obraz byl pak použit jako vstup pro deformační obrysový model [9].

Ke zjištění endokardiálního obrysu byl aplikován deformovatelný obrysový algoritmus na všechny výškové roviny 3D. Při transformaci tohoto předpokladu na hraniční podmínky deformovatelného obrysového algoritmu je obrys v aktuální rovině optimalizován použitím kontur sousedních rovin v čase a místě. Pro inicializaci algoritmu byl první obrys vypočítán v systolické fázi v nejpřednější rovině 3D datové sady bez optimalizace z hlediska kontinuity. Pro každý rámec byly kontury

endokardu získané optimalizovaným deformovatelným obrysovým algoritmem kombinovány za účelem vytvoření endokardiálního povrchu [9].

Deformovatelný obrysový algoritmus byl aplikován na 3D datovou množinu získanou během plného cyklu srdce pro nalezení endokardiálního povrchu. Lepších výsledků se dostane, když si zobrazíme všechny roviny zvlášť (Obrázek 8) [9].



Obrázek 8: Separovaná segmentovaná rovina [9].

1.2.3 Shape Regression Machine

Autoři se zabývali přístrojem nazvaným Shape Regression Machine (SRM) tzv. tvarovací regresní přístroj k segmentaci anatomických struktur v reálném čase. Tradiční segmentace struktur v obraze užívají hran v objektu, jakožto definované okraje objektu. Variační segmentace zase předpokládají, že oblast uvnitř objektu ohraničeného konturou mají homogenní intenzitu. Všechny metody však potřebují výbornou inicializaci oproti SRM, který není ničím omezen [4].

Dvoustupňový přístroj SRM využívá:


1. Definovaný klinický kontext anatomických struktur,
2. databázi různých tvarů a patologií anatomických struktur srdce [4].

V první fázi hledá objekt pro spuštění inicializace pomocí jednoho snímku. V druhé fázi se porovná první inicializační snímek s databází a nelineární regresor začne předpovídat další změny tvaru a vzhledu srdce v obraze. Autoři tento přístroj testovali u endokardu levé srdeční komory [4].


Princip SRM

SRM Přístroj nepředstavuje žádná omezení. Nutně nepotřebuje hrany objektu, homogenitu jasové stupnice a dokáže probíhat v reálném čase [4].

V prvé řadě používá binární klasifikátor. Vzhledem k tomu, že vybraný střed zájmu je spojen s databází anatomických snímků srdce, přístroj ví, jaké geometrické parametry objektů přibližně hledat (Obrázek 9). Z databáze si určí trénovací množinu pro binární klasifikátor pouze z jednoho snímku, který když danou databázi projde, ohraničí oblast zájmu od pozadí, a poté skenuje anatomickou oblast v reálném čase. Učením se aproximuje na námi vyšetřovanou oblast, a zároveň dokáže brát v potaz pravděpodobnost chyb a regresivně je použit v segmentaci pro ještě kvalitnější výsledek. Algoritmem je regresní funkce navržena vzhledem ke skenovanému snímku. Ve srovnání s jednotlivými vybranými snímky z databáze tak co nejvíce koresponduje a přizpůsobuje se, aby lokalizoval hledanou anatomickou strukturu (Obrázek 10) [4].



Obrázek 9: Oblasti zájmu pomocí SRM [5].



Obrázek 10: Tréninková množina snímků z databáze postupně trénující regresor [5].

Důležitým zjištěním se stalo, že trénink regresora, který se poté adaptuje na anatomickou strukturu srdce s následnou detekcí trvá i několik dní, avšak se vyplatí vzhledem k výsledku. Nejeftivněji se osvědčilo po nasazení oblasti zájmu nastavení funkce spojené s trénovaným detektorem, který zpětně uvažuje chyby algoritmu a upravuje konturu ohraničující srdce [4].

Přístroj SRM tak vymezuje detekci anatomických struktur bez skenování ve všech směrech s menší náročností výpočtů. Regresivní funkce v SRM dokáže být natolik dokonalá díky poskytnuté databázi snímků, a proto jednoznačně převyšuje metody jiné regresní metody jako například AAM [4].

2 Dynamická Echokardiografie

Ve své podstatě se jedná o ultrazvukové vyšetření srdce v dynamickém režimu. Ultrazvuk o velmi vysoké frekvenci snímá srdce v rychlých intervalech se zobrazením těchto snímků za sebou, a tudíž vytváří video. Vysoká frekvence ultrazvuku je inicializována piezoelektrickou sondou, která se přikládá na hrudník. Po vyslání ultrazvukové vlny sondou se čeká na odrazy vln ze srdce, které jsou analyzovány a převedeny na pohybující se obraz srdečních stěn a struktur. Dokážeme tak získat informace o srdečních oddílech a jejich velikostech, struktuře a funkcích. Patří mezi základní kardiologické vyšetření díky neinvazivnímu, šetrnému, rychlému a levnému přístupu k informacím o srdci.

2.1 Formování echokardiografického obrazu

Zdrojem UZV vln je sonda z piezoelektrických krystalů. Generování vlny spočívá v přivedení vysokofrekvenčního střídavého napětí, kterým vznikne mechanická deformační energie a vyslání vlny k srdci. Následně se vrací echa, což jsou posloupné odražené vlny nesoucí informaci o zkoumané tkáni. Echa zachycuje AD převodník a přiřazuje každému číselný údaj odpovídající intenzitě tedy stupňů šedi v obraze. Kvalita získaného obrazu závisí na vhodném nastavení ultrazvukového módu pro konkrétní anatomickou strukturu a frekvenci [11,13].

2.1.1 Módy Echokardiografie


Existují tři základní typy módů:

- a) B-mód
- b) M-mód
- c) Dopplerovská echografie

B-mód

Režim B je nejčastěji používaným zobrazovacím režimem. Může být buď dvourozměrný nebo trojrozměrný (díky nedávným pokrokům v echografických sondách) a umožňuje tak zobrazení hloubky i šířky (v 2D) nebo tloušťky (ve 3D). Výsledku se dosáhne opakovaným šířením UZV paprsku všemi směry. Poloha pak závisí na čase letu a na směru šíření ultrazvukového paprsku. Postup umožňuje 50-70 snímků ve 2D nebo 20-30 ve 3D [10].

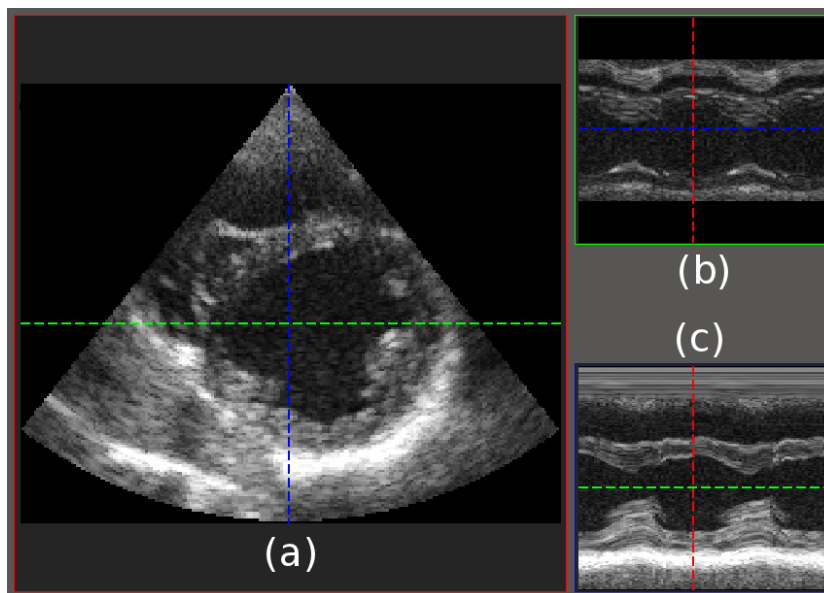
B-mód se využívá například k průkaznosti patologických struktur jako jsou tromby, nádory, posouzení struktury a pohybu chlopní, nemoci perikardu, určování tloušťky srdečních stěn a komplikací u infarktu myokardu (Obrázek 11).



Obrázek 11: B-mód ultrazvuku s vysvětlením srdečních struktur. Upraveno z [10].

M-mód


Tento režim umožňuje vidět velmi rychlé pohyby a dosáhnout vyšší časové rozlišovací schopnosti než režim B, ale vyžaduje, aby sonda byla pečlivě přiložena k tělu. Níže (Obrázek 12) je zobrazen M-mód spolu s odpovídajícím obrazem režimu B. UZV paprsek se pozoruje v průběhu času, a tak pohyby srdce vyvolávají změnu polohy amplitudy přijatých ech [10].



Obrázek 12: B-mód se zainteresovaným M-módem. (a) parasternální pohled. (b) zobrazení M-módu zelené vodorovné linie v (a). (c) zobrazení módu modré linie v (a). Převzato z [10].

Dopplerovská echografie

Vyhodnocuje směr a rychlost průtoku krve srdcem v závislosti na čase názornou vizualizací. Režim přijímá signál s posunutou frekvencí vzhledem k vysílanému signálu. Je však důležité mít během zkoušky konstantní úhel dopadu vln. Výstupem může být buď zvukový signál nebo rychlostní křivka s barevným kódováním vzhledem k času. Průtok směrem k sondě je značen obvykle červeně, a naopak od sondy modře (Obrázek 13) [10, 11].



Obrázek 13: Dopplerovské zobrazení ve 2D [10].

2.1.2 Piezoelektrická sonda

Typický ultrazvukový systém používá snímač sestávající z řady piezoelektrických prvků pro přenos zvukového impulsu do tkáně. Piezoelektrické prvky tvoří hlavní část měniče, protože přeměňují elektrickou energii na akustickou energii a naopak [10].

U kardiálního zobrazování (Obrázek 14) se paprsky vysílají sektorovými sondami (Obrázek 15), jelikož je přístup k srdci přes ostatní tkáňové struktury obtížný a emitované vlny umožní obraz v široké oblasti. Proto je dostačující užití nižší frekvence od 2–5 MHz.

Vhodným pro zobrazení srdečních struktur se také stávají kvůli elektronickému vychylování svazku v sondě s úzkou základnou, protože při užití mechanické sondy se svazek musí vychylovat mechanicky otáčením hlavice. Měníče jsou uspořádány do krátké lineární řady se současným buzením ale různou fází. Jednotlivá echa se vrací po různých časových prodlevách zpět, kde se časově srovnávají a detekují lineární řadou [10, 11].



Obrázek 14: Snímek z echokardiografického vyšetření srdce pomocí sektorové sondy, převzato z [12].



Obrázek 15: Vzhled sektorové sondy, upraveno z [11].

3 Klinické využití Echokardiografie

V následujících dvou tabulkách jsou popsány sledované parametry u srdečních komor (Tabulka 3), a také fyziologické hodnoty měřené v Echokardiografii (Tabulka 2).

Tabulka 2: Fyziologické hodnoty srdečních struktur [18].

Fyziologické hodnoty v Echokardiografii		
	<i>Velikosti srdečních dutin</i>	<i>Tloušťky stěn srdečních dutin</i>
Levá síň	< 22mm/m	
Levá komora	< 31 mm/m	
Pravá komora	31 mm	< 5 mm/m
Zadní stěna LK		6 – 10 mm
Mezikomorové septum		6 – 12 mm

Tabulka 3: Sledované parametry u echokardiografického vyšetření [19, 20].

Sledované parametry v Echokardiografii		
	Zkratka	Jednotka
		<i>[mm]</i>
Rozměr LK na konci diastoly	Dd	40 – 56
Rozměr LK na konci systoly	Ds	28 – 40
Tloušťka zadní stěny LK (ZS)	ZS	4 – 12
Tloušťka mezikomorového septa	IVS	7 – 12
Rozměr levé síně	LS	25 – 40
Rozměr aorty	Ao	22 – 40
		<i>[mm/m²]</i>
Plocha LK na konci diastoly	LKd	31 – 32
Ejekční frakce		59 – 75 %

3.1 Patologické nálezy v Echokardiografii

Popsána je celá řada kardiologických onemocnění. Mezi nejčastější patří níže zmíněné, k jejich diagnostice se užívá právě Echokardiografie.

Aortální stenózy

Neboli zúžení aorty je nejlépe prokazatelné v Dopplerovském režimu, kde pozorujeme nepravidelný nebo nedostačující průtok krve. Důsledkem bývá hypertrofie LK s poklesem její kontrakility, kdy není schopna překonávat odpor aorty a krev v ní městná.

Aortální, dvojcípá a trojcípá insuficience


Aortální nedostatečnost nastává při degenerativním poškození aortálních cípů, jehož následkem dojde k přetížení LK a její hypertrofii. K nedostatečnosti dvojcípé chlopně dochází objemovým přetížením k rozšíření levé síně a poté i komory. Trojcípá nedostatečnost vzniká v důsledku dilatace PK kvůli plicní hypertenzi [17, 18].

Hypertrofická a dilatační kardiomyopatie

Oba druhy jsou podmíněné geneticky s poškozením srdečního svalu, myokardu. Hypertrofická kardiomyopatie se vyznačuje insuficiencí dvojcípé chlopně a hypertrofií LK (především však mezikomorové přepážky) [17]. Při dilatační kardiomyopatii dochází k dilataci PS se zvýšením plicních tlaků PK s možností následné fibrilací síní [17, 18].

3.2 Srdeční osy a pohledy u vyšetření srdce

Srdeční přístupy v Echokardiografii se dělí na několik pohledů, os (Obrázek 16). Jednotlivé metody jsou vysvětleny v kapitole dále.



Obrázek 16: Znázornění srdečních os [19].

3.2.1 Parasternální vyšetření

Jedná se o základní úroveň projekce v Echokardiografii v závislosti na umístění sondy v konkrétních částech hrudníku pro snadnější přístup ke hledaných srdečním partiím. Zároveň se tato projekce užívá při celkovém hodnocení vitality srdce. Nevýhodou projekce je neschopnost vidět celý hrot srdce [17].

V tzv. *dlouhé ose* nejlépe hodnotíme funkci pravé a levé komory v systolické fázi a dále morfologie dvojčipé a aortální chlopně. Můžeme také pozorovat výtokovou část z levé komory (LK) [17]. V projekci dlouhé osy je LK rozdělena na pět segmentů, a to bazální posteriorní a anteroseptální, střední posteriorní a anteroseptální a oddíl apikální [17].

V tzv. *krátké ose* se části dělí členitěji. Máme 6 oddílů u dvojčipé úrovně, 6 oddílů v úrovni papilárních svalů a 4 oddíly v apikální úrovni. Dále se v těchto úrovních dělí v závislostech na úhlech pohledu, tak jako u dlouhé osy. Nejčastěji se krátká osa využívá k hodnocení PK, LK a morfologie trojčipé a plicnicové chlopně. Můžeme hodnotit cípy aorty, jejich hybnost, kalcifikaci, případnou bikuspidalitu a vrozené vývojové vady aortální chlopně. Při Dopplerovském režimu dokážeme také odhalit hypertrofii PK a defekty síňového septa [17].

3.2.2 Apikální vyšetření

Čtyřdutinová apikální projekce slouží k Dopplerovskému měření trojčipé, dvojčipé a aortální chlopně. Zobrazujeme například vyústění plicních žil a hrot srdce. Výhodou je viditelnost srdečních kontur a separovaných cípů [17].

Pětidutinová projekce jako nástavba čtyřdutinové, která navíc zobrazí i aortální kořen a část ascendentní aorty navíc s globální ejekční frakcí.

Doplňková *dvoudutinová apikální projekce* zobrazuje hrot a kontraktilitu srdce

Třídutinová apikální projekce je doplňkem dvoudutinové, kdy dostáváme ještě další směr s pohledem na výtokovou a vtokovou část do LK. Proto se užívá pro nejasné vtoky právě v LK.

3.2.3 Subkostální vyšetření

Užívá se čtyřdutinové projekce tak jako u apikálního vyšetření s výhodou vyšetřovací polohy pacienta na boku s umístěním sondy na mečovitý výběžek hrudní kosti. Pro pacienty s emfyzémem plic nebo chronickou obstrukční chorobou plicní se tak jedná o šetrnější vyšetření. Zároveň získáváme nejlepší pohled na pravou síň a komoru, při kterém objektivně měříme tloušťku jejich stěn například u hypertrofie PK [17].

3.2.4 Suprasternální vyšetření

Nejkvalitnější zobrazení aortálního oblouku a descendentní aorty pro určení její stenózy a vyloučení zpětného proudění krve. Sonda se přikládá do suprasternální jamky [17].

PRAKTICKÁ ČÁST

Základem praktické části je zhodnocení a seznámení s problematikou poskytnutých echokardiografických obrazových dat v celé práci. Zároveň se analýza dat zabývá jednotlivými druhy šumů a hodnotícími parametry pro míru degradace obrazových dat, které jsou poté používány u testování v kapitole 7. Stěžejní v praktické části je implementace algoritmu bezhranových aktivních kontur.

Segmentační algoritmy, které se na obrazová data aplikují, však díky nepřesnostem a šumu v obraze nejsou natolik robustní, aby ze surových dat dokázaly vyčlenit srdeční struktury a patologie. Cílem bylo tedy nejprve předzpracování obrazu, které se používá pro optimalizaci jasových a strukturálních charakteristik, což předurčuje lepší rozeznatelnost zájmových objektů. Proto bylo provedeno předzpracování pomocí filtrů a jasových transformačních funkcí obrazu se snahou obraz co nejlépe připravit a zviditelnit pro lidské oko, aby následně segmentační algoritmus dokázal pracovat účinněji.

Po tomto kroku proběhla implementace segmentačního algoritmu s následnou extrakcí modelu srdeční síně nebo komory s následným měřením srdečních parametrů (délka, šířka, těžiště, objem) v separovaných objektech s hodnocením měřených výsledků v rámci porovnání s fyziologickými parametry srdce.

Dále byly všechny datové sady snímků zatíženy pomocí umělého generátoru šumů několika různými parametry a typy šumů. Gaussův šum, Salt and Pepper šum a šum typu speckle postupně degradoval všechny snímky a následně byl na všechny tyto zatížené snímky šumem aplikován stejný segmentační algoritmus s totožným nastavením, který segmentoval snímky předzpracované, tudíž kvalitnější. Dále se všechny extrahované segmentované modely z dat zatíženými šumy porovnávaly s modely, které byly extrahovány z předzpracovaných obrazů pomocí hodnocení míry degradace obrazových dat, a to korelací, střední kvadratickou chybou, strukturální podobností a DICE koeficientem.


Následující kapitola byla zaměřena na sledování dynamických srdečních parametrů, tedy měření délky, šířky, objemu a těžiště u několika řezů snímků najednou. Konečným výsledkem praktické části bylo toto dynamické sledování parametrů zároveň i se sledováním parametrů u jednoho snímku vložit do přehledného GUI pro uživatelské ovládání.

Všechny kroky popsané v této kapitole jsou dále rozváděny a vysvětleny v následujících kapitolách diplomové práce.


4 Struktura obrazových dat

V předešlých kapitolách bylo echokardiografické vyšetření zmíněno jako jedním z nejběžnějších vyšetření srdce. Výsledný obraz však někdy není průkazný a mnohdy u některých anatomických struktur nelze přesně určit jeho hranice. Zde vyvstává problém pro klinické pracovníky a snaží se jej eliminovat, aby mohly eventuální patologie odhalit.


Ukázky echokardiografických snímků použitých v této práci jsou vyobrazeny v následujících obrázcích níže (Obrázek 17, Obrázek 18, Obrázek 19). Byly vybrány tři datové sady. Datová sada I o počtu 13 ti snímků, datová sada II o 11 ti snímcích a datová sada III o 12 ti snímcích. Od všech těchto obrazových struktur se odvíjela celá práce.



Obrázek 17: Obrzy z datové sady I.




Obrázek 18: Obrzy z datové sady II.



Obrázek 19: Obrzy z datové sady III.

4.1 Typy šumů

V rámci analýzy dat existuje řada šumů, kterými může být snímek znehodnocen. Nejběžnějším šumem v UZV snímcích je speckle šum dále Gaussův a Salt and Pepper. S těmito druhy šumů se dále v práci pracuje a uměle se jimi zatěžují snímky pro hodnocení robustnosti segmentačního algoritmu v kapitole 7.




Obrázek 20: Příklad echokardiografického snímku s rozpoznáním srdečních struktur [upraveno z 10].

4.1.1 Speckle noise

Šum, vyvolávající granulární aspekt v obraze vede k vytvoření nehomogenního obrazu v jinak homogenních tkáních [14]. Definuje se polem odrazivosti neboli jeho rozptylem (v).

Jev nastává v důsledku útlumu amplitudy signálu měnící se s hloubkou. Při samotném vyšetření se ultrazvukovému šumu dá vyvarovat důkladným spojením sondy s kůží pomocí gelu. Rozdílné odpory tkání způsobí velký odraz. Je třeba aby se tkáně, kterými prostupuje paprsek, impedančně přizpůsobily, a proto se nanáší gel mezi sondu a pokožku.

Příklady snímků zatížených speckle šumem (Obrázek 21).



Obrázek 21: Zobrazení echokardiografických dat zatížených umělým speckle šumem o rozptylu 0,04.

Čím větší frekvence, tím detailnější obraz ale menší hloubka [16]. Při echokardiografii se příslušné frekvence pohybují v rozmezí 2 až 5 MHz, a pro tento rozsah hodnot je velikost pixelu přibližně jeden krychlový milimetr. Kdybychom použili frekvenci nižší, získali bychom sice podrobnější obraz, ale nemáme jistotu, že ultrazvukové vlny by se dostaly až k srdci a poskytly tak hledané informace o srdci.


Echogenita, jakožto schopnost odrážet UZV vlny se dělí:

1. **Anechogenní:** Žádná schopnost odrazu= černé oblasti ve snímku. Jsou to místa, kde se vyskytují tekutiny (krev, výpotky).
2. **Hypoechogenní:** Odrazivost minimální= tmavě šedé oblasti ve snímku.
3. **Hyperechogenní:** Odrazivost vysoká= světle šedé až bílé oblasti.
4. **Izoechoenní:** Podle vzájemného působení echogenit mezi sebou jsou oblasti v sobě rovném stavu [15].

Obrázek 20 zobrazuje srdeční komory. Klíčovým pro kliniku je tyto komory kvalitněji rozlišit, ohraničit a odseparovat. Poté můžeme například měřit velikosti srdečních komor, tloušťku stěny srdečního svalu a pozorovat pohyby a změny struktury s patologiemi.

4.1.2 Gaussův šum


Vyznačuje se normálním rozložením šumu na všech pixelech stejnou mírou. Definují se a ovlivňují jej parametry průměr (m) a rozptyl (v). Intenzita Gaussova šumu neklesá s rostoucí frekvencí a celý obraz zatěžuje rovnoměrně. Ukázky snímků zatížených Gaussovým šumem (Obrázek 22).



Obrázek 22: Degradace ultrazvukového obrazu Gaussovým šumem pro užití k testování. Rozptyl všech šumů: $v=0,01$. Nahoře vlevo: $m=0,01$, vpravo: $m=0,1$, dole: $m=0,02$

4.1.3 Šum Salt and Pepper

Jedná se o impulsní šum. Vyznačuje se posetím obrazu černými a bílými pixely nespočetnými s původním obrazem. Je udáván jedním parametrem, a to hustotou těchto nežádoucích pixelů – hustota šumu (d). Šum může být způsoben ostrými náhlými poruchami obrazového signálu. Příklady echokardiografických snímků zatížených šumem Salt and Pepper (Obrázek 23).



Obrázek 23: Postupná degradace ultrazvukového obrazu šumem Salt and Pepper pro užití k testování.

Nahoře vlevo $d=0,001$, vpravo: $d=0,01$, dole: $0,02$

4.2 Měření míry degradace obrazových dat

V kapitole 7 jsou uvedeny výsledky porovnání segmentovaných struktur právě mezi extrahovanými modely z předzpracovaných snímků a mezi modely ze snímků uměle zatížených šumem díky hodnotícím parametrům o degradaci obrazu. Jejich principy jsou popsány níže a dále v práci jsou uvedeny shrnutí výsledků. Jedná se o strukturální podobnost (SSIM), Střední kvadratickou chybu (MSE), korelaci (CORR) a DICE koeficient.

4.2.1 DICE koeficient

Koeficient pracuje na základě znalosti o množství pixelů obsažených ve dvou měřených obrazech a udává procentuální zastoupení podobnosti díky množství pixelů v obou srovnávaných. Hodnotí tedy počty pixelu v obou modelech a dává výsledek do poměru značící procentuální zastoupení. Koeficient komparuje pouze binární obrazy, kde X a Y jsou dvě porovnávané množiny (rovnice (1))

$$D(X, Y) = \frac{2|X \cap Y|}{(|X| + |Y|)} \quad (1)$$

4.2.2 Strukturální podobnost (SSIM)

Jedná se o podobnostní index mezi dvěma obrazy. Nabývá hodnot od -1 do 1, přičemž při hodnotě 1 se jedná o maximálně shodnou podobnost, tudíž totožnost obrazů. Ze skutečností vyplývá, že má klesající charakter. Čím více jsou si obrazy nepodobné, tím je hodnota indexu menší. Z definice vyplývá, že při zvyšování šumu se dostává nižších hodnot podobnosti, tudíž se reprezentuje jako klesající charakteristika (Obrázek 24).

Strukturální podobnost je závislá na třech podmínkách, a to podmínka jasu (l) (rovnice (2)), kontrastu (c) (rovnice (3)) a struktury (s) (rovnice (4)). Kombinací podmínek se získává konečný index SSIM (rovnice (5)).


$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (2)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (3)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (4)$$

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (5)$$

V popisujících rovnicích je vysvětlen princip výpočtu indexu SSIM, kde μ_x , μ_y , jsou průměry každého z obrazů, σ_x , σ_y jsou směrodatné odchylky obrazů, σ_{xy} je křížová kovariance obrazů (míra lineární závislosti dvou obrazů) a C vyjadřuje dynamický rozsah hodnot pixelů [22].




Obrázek 24: Ideální závislosti SSIM na rostoucích parametrech Gaussova šumu.

4.2.3 Střední kvadratická chyba (MSE)

Vyjadřuje míru difference díky spočtení středních hodnot druhých mocnin rozdílů (rozptyl chyb) mezi v tomto případě nativním a šumovým modelem separace srdeční struktury. Hodnoty MSE jsou vždy nezáporné (díky druhé mocnině) a nulové jsou pouze v případě, že jsou obrazy totožné. Tudíž se při nižší hodnotě zvyšuje podobnost mezi modely. Charakteristika má rostoucí průběh, jelikož při zvyšování obrazového šumu se dostává větších chyb (Obrázek 25).

Od získaného šumového modelu Y_I se odečte nativní model a celá tato operace se umocní. Celý vztah je v rovnici (6).


$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_1 - \widehat{Y}_1)^2 \quad (6)$$



Obrázek 25: Ideální závislosti MSE na rostoucích parametrech Gaussova šumu.

4.2.4 Korelace (CORR)

Korelace určuje podobnost, vztah mezi dvěma obrazy a říká o linearitě mezi nimi. Míra korelace se specifikuje koeficientem nabývajícím hodnot -1 až 1. Kladná hodnota pojednává o přímé závislosti obrazů. Při chování charakteristik korelací jsou při zvyšujícím se šumu hodnoty korelací menší, a tudíž charakteristiky zobrazují klesající charakter (Obrázek 26)



Obrázek 26: Ideální závislosti CORR na rostoucích parametrech Gaussova šumu.

5 Metoda aktivních kontur

Z vytvořené řešerše (kapitola 1) je zřejmé, že tato metoda patří mezi pokročilejší v segmentaci obrazu. Proto také byla vybrána jako objektivní a robustní při aplikaci na ultrazvukových snímcích, které se vyznačují špatným kontrastem a viditelností hran objektu.

Existuje řada jejích modifikací, a zároveň spadá do deformovatelných modelů. Hlavní princip spočívá v definování křivky v obraze, inicializační kontury, která se postupně deformuje své morfologické vlastnosti na základě počítaných energií v jednotlivých iteracích. Jedná se o uzavřenou křivku, která dokáže vyhledat a nahradit tvar objektu dokonce i u neurčitých hran, jelikož umí využít statistické rozložení pixelů. Kontury můžeme v obecném dělení chápat jako aktivní kontury založené na detekci hran a aktivní kontury zaměřené na statistickém rozložení pixelů (aktivní kontury bez hran).

5.1 Hranové, parametrické aktivní kontury


Křivka je prezentována vnitřními a vnějšími energiemi. Hladkost, stejnorodost a soustavnost křivky má v oblasti zájmu energie vnitřní. Přitahuje tak křivku k hranám, vytváří její obrys a záleží pouze na aktuálním stavu po určité iteraci. Vnější naopak reprezentují a berou v potaz původní umístění kontury – pozici a čas. Po součtu těchto dvou energií v jednotlivých iteracích dostáváme kompletní konturu [21].

5.2 Geometrické aktivní kontury se statistickým rozložením pixelů – level-set

Metoda aktivních kontur je velmi úzce propojená s nastavením level-set funkce, jejíž prostřednictvím se nastavuje kontura. Užívá se při složitější vymezených objektech, kde nejsou známy jeho parametry. Charakterizuje se menší senzitivitou vzhledem k šumu oproti parametrickým aktivním konturám. Pracuje také ve více dimenzích, což ale pro tuto práci není potřeba. Následně bude popsán zjednodušený výklad a jádro této metody ve spojitě oblasti.

Prvotním krokem při inicializaci, určuje level-set funkce nastavení tzv. nulové hladiny, řezu skrz hledaný objekt. Každému pixelu ve 2D dimenzi, x a y , je přiřazena výška nad inicializační nulovou hladinou. Vzdálenost a hodnota každého pixelu se přiřazuje podle pravidla, jestli pixel do inicializační kontury patří, nebo je mimo ni [21].

Pixelům uvnitř se přiřazuje znaménko záporné, tedy oblast Ω_- . Naopak pixelům vně konturu přiřazujeme znaménko kladné, tedy oblast Ω_+ (Obrázek 27). Číselná hodnota pixelů je počítána vzhledem k základní nulové hladině.



Obrázek 27: Rozdělení inicializační oblasti kontury.

Tímto byly přiděleny číselné hodnoty pixelům, které postupně dle průchodu iterací budou přepočítávat původní nulovou hladinu až k finálnímu výsledku minimalizace energie a separaci objektu konturou. Přepočítávání nulové level-set hladiny je ovlivněno tzv. kernelovou funkcí podle níž je kontura v dalším kroku počítána.

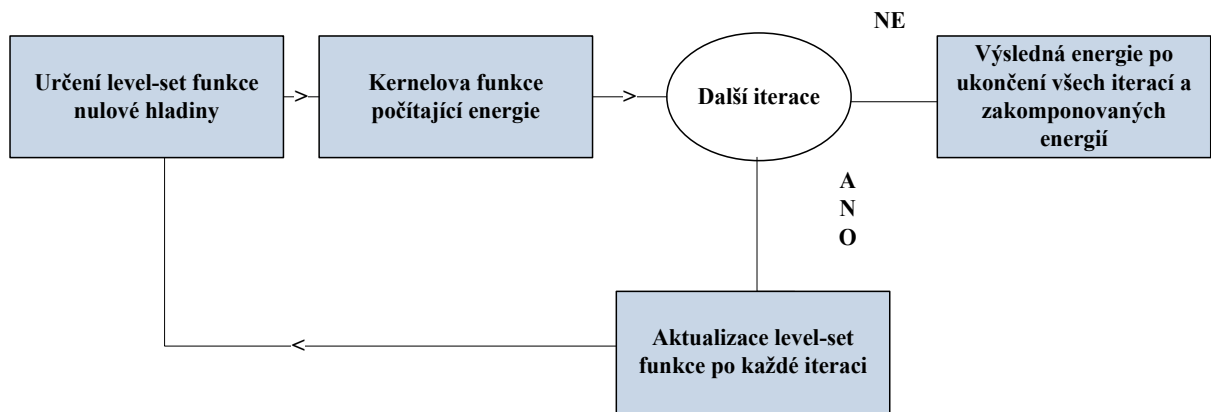
Kernelova funkce podává informace o velikosti filtračního jádra, tudíž jak velký a značný posun kontury bude při průchodu každé iterace. Je popsána Gaussovou statistickou distribucí s hodnotami pro její průměr a rozptyl. Pokud nastavím kernelovou funkci menší, počítá rychleji, ale bude brát v potaz menší počet pixelů, což může mít za následek nedostatečnou evoluci kontury [21].

V rovnici (7) je popsán výpočet kernelovy funkce v jedné iteraci. Představíme si obraz, ve kterém je objekt, který chceme odseparovat určený Ω_- (pixely uvnitř objektu) a Ω_+ (pixely vně objektu). Hodnoty v těchto množinách Ω zároveň představují průměrné hodnoty intenzity v obou prostorech, tedy informaci o jejich hodnotách průměru a rozptylu. Parametry $n_{x,y}$ dávají informace o jednotlivých hodnotách intenzity, H_p představuje hranici okraje křivky a hladkost s tím, že p jsou určité body hranice.

$$E(\Omega_+, \Omega_-, H) = \int (n_{x,y} - \Omega_+)^2 dx dy + \int (n_{x,y} - \Omega_-)^2 dx dy + \int |H_p| dp \quad (7)$$

Známa Heavisidova funkce klasifikuje obrazovou doménu dle její konvence na oblast zájmu a pozadí. Tam, kde bude funkce větší nebo rovna nule, přiřadím hodnotu 1 = oblast hledaná, a naopak.


Poté se jednotlivé oblasti integrují, sečtou a dostane se nová hodnota energie při jedné iteraci, podle níž se aktualizuje hodnota inicializační nulové level-set funkce a pokračuje se na další iteraci až do úplného průchodu nastaveného počtu. Energie vnitřních a vnějších sil se postupně minimalizuje tam, kde má nejmenší energii až po konečný výsledek. Vývojový diagram celého procesu je popsán níže (Obrázek 28).



Obrázek 28: Vývojový diagram regionálních aktivních kontur pomocí level-set.

6 Implementace algoritmu geometrických aktivních kontur

Celý algoritmus výše zmíněných aktivních kontur byl spouštěn a nastavován v prostředí MATLAB®. Po zhodnocení kvality rozlišení poskytnutých echokardiografických snímků na začátku implementace, se došlo k závěru, že by bylo vhodné obrazy nejprve předzpracovat tedy v prvních krocích použít filtrování a zesílení jasu před počáteční inicializací kontury. Následovalo vhodné nastavování aktivních kontur pro separaci srdečních objektů (síní a komor). Po nalezení vhodného nastavení a vymezení hledaného modelu konturou, došlo na převedení obrazu do binární podoby. Vychází tak binární obraz, kde pixely ležící uvnitř kontury (hledaná srdeční struktura) mají hodnotu 1 a pixely ležící mimo objekt mají hodnotu 0. Konečným krokem celého procesu bylo měření délek hlavních a vedlejších poloos v odseparované srdeční komoře nebo síní, a tím zjištění parametrů o srdci. Celý krátce popsany vývoj procesu je intuitivně znázorněn v diagramu (Obrázek 29) a dále v textu se jednotlivé bloky popíšu dopodrobna.




Obrázek 29: Vývojový diagram procesu nalezení srdečních struktur.


6.1 Načtení snímku

Pro celou práci bylo poskytnuto několik datasetů. Jednalo se o snímky z jak už zmíněné dynamické Echokardiografie, tudíž mnoho dat, jelikož byly získány z videa. Vybrané sety snímků byly rozděleny do tří datových sad snímků, které byly i dále v práci testovány. Nyní se popíše konkrétní práce se všemi daty, ale pro názorné zobrazení se pracuje pouze s jednou sadu snímků, na kterých jsou popsány všechny operace z výše uvedeného diagramu. Všechny ostatní obrazy z dalších datasetů budou uvedeny v přílohách práce.

Prvním krokem algoritmu je načtení snímků. Pro lepší interpretaci se uvažuje o souboru třinácti snímků v jednom datasetu. Pomocí funkce *dir* byly načteny všechny snímky, které jsou součástí složky, ve které je uložen skript programu. Pro uchování do paměti se data umístí do matice, tudíž se získala struktura o jednom sloupci, kde v jednotlivých řádcích je samostatně uložen každý obraz. Do druhého sloupce matice byla uložena tato data s konverzí RGB na monochromatický obraz díky funkci definované MATLABem. Obrázek 31 zobrazuje snímky celé datové sady.




Obrázek 30: Načtení nativního snímku.



Obrázek 31: Zobrazení všech nativním snímku datové sady I


6.2 Předzpracování obrazu

V následujícím, třetím sloupci matice byla načtena předpracovaná data pomocí funkce *preprocess* nadefinované v samostatném skriptu obsahující parametry pro aplikaci metod.



Obrázek 32: Vývojový diagram předzpracování obrazu.

Všechny kroky předzpracování obrazu jsou uvedeny v blocích diagramu (Obrázek 32). První blok představoval zesílení obrazu tedy zviditelnění jasu monochromatického obrazu. Jedná se o jasovou transformaci, která mění původní vstupní hodnotu jasu obrazu na výstupní. Parametry jasové funkce nabývají hodnot 0 až 1, což se představuje jako 0 % až 100 %.



Obrázek 33: Graf znázorňující jasovou transformaci k předzpracování obrazu.


Zjednodušeně řečeno byla zesvětlena původní 0% nejmenší vstupní hodnota jasu na výstupní 10% a původní 60% největší vstupní hodnota jasu na výstupní 90% (Obrázek 33).

K další modifikaci obrazu přispěl modifikovaný Laplacianův vysokofrekvenční filtr pro zvýraznění hran, matice v rovnici (8), která slouží jako konvoluční maska a postupně klouže po celém obraze s přepočítáním nové hodnoty vzhledem k parametrům matice. Dochází tak k násobení každého pixelu v obraze konvoluční maskou hranového filtru s uložením do obrazu nového funkcí 2D cyklické konvoluce.


Hranový filtr detekuje oblasti (pixely), kde dochází k prudké změně jasu, a tedy se předpokládá, že nese významnější informaci o hranicích objektu. Hrana je dána vlastnostmi obrazového elementu a jeho okolí a popisuje rychlost změny a směr růstu

$$H = \begin{pmatrix} 0 & -1 & 0 \\ -1 & 5 & -1 \\ 0 & -1 & 0 \end{pmatrix} \quad (8)$$

Konečnou úpravou v předzpracování obrazu se stala aplikace filtru funkcí 2D mediánového filtru s velikostí jádra 5×5 . Tudiž se jednalo o jednotkovou matici této velikosti, kdy opětovně jako u hranového filtru se filtr přikládá na každý pixel v obraze a počítá mediány, které se pak zpětně uloží do obrazu nového (Obrázek 34).



Obrázek 34: Předzpracovaný obraz.



Obrázek 35: Zobrazení všech předzpracovaných snímků datové sady I

Do dalších sloupců vytvořené matice se v následující části práce ukládají nativní obrazy, které se uměle ovlivní různými typy šumů pro testování robustnosti segmentačního algoritmu v kapitole 7.

6.3 Návrh segmentační procedury pro genezi modelu srdečních struktur

Pro zmenšení výpočetní náročnosti bylo nutné provést kompresi předzpracovaných obrazů i za předpokladu, že dojde ke zhoršení kvality obrazu na poloviční hodnotu a převedení do datového typu s dvojitou přesností pomocí formátu na double.

K určení hledané struktury byl aplikován do obrazu pohyblivý kurzor, kterým při manuálním kliknutí do snímku vymezí objekt neboli oblast zájmu určité srdeční struktury jakožto interaktivní vstup uživatele pro lokalizaci těžiště inicializační kontury.

Při nastavování vhodných parametrů aktivní kontury (Parametry segmentační procedury byly stanoveny experimentálně, vývojem a z nastudovaných vlastností o konturách. Do prostředí MATLAB byly zadány a uloženy a následně zakomponovány do Gaussova modelu vyhlazování, kde postupně začala být prvotně nastavená nulová hladina kontury přepočítávána s každou příchozí iterací a přepočtem kernelovy funkce, tak jak bylo vysvětleno v kapitole 5.2.

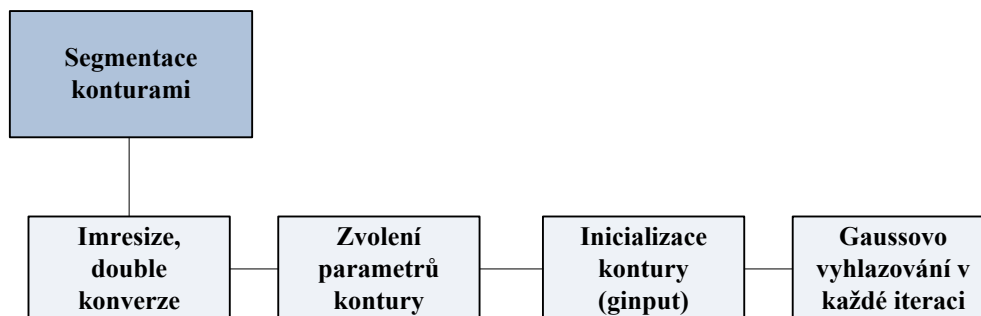
Tabulka 4 Experimentálními implementacemi a dlouhodobým studováním jejich parametrů se algoritmus optimalizoval až do nejefektivnější možné segmentované části pro konkrétní datové sady (Tabulka 4).

Parametry segmentační procedury byly stanoveny experimentálně, vývojem a z nastudovaných vlastností o konturách. Do prostředí MATLAB byly zadány a uloženy a následně zakomponovány do Gaussova modelu vyhlazování, kde postupně začala být prvotně nastavená nulová hladina kontury přepočítávána s každou příchozí iterací a přepočtem kernelovy funkce, tak jak bylo vysvětleno v kapitole 5.2.

Tabulka 4: Specifikace a parametry aktivní kontury.

Specifikace aktivní kontury		
Parametry kontury	Vlastnosti	Zvolené parametry
Počet iterací	Volíme s ohledem na délku trvání segmentace. Pokud nastavíme pro daný objekt iterací málo, kontura se nedostatečně přesune do hranových oblastí, ale pokud nastavíme iterací mnoho, proces trvá déle a kontura může přesídlit na jiný objekt v obraze.	1800
Časový krok	Čím menší zvolíme, tím pomaleji každá iterace probíhá, ale při zvětšení časového kroku může dojít k odskočení kontury do jiného objektu v obraze.	0,005 s
Velikost kernelova jádra	Čím menší velikost se nastaví, tím pracuje kontura rychleji, ale bere v potaz menší počet okolních pixelů, a nemusí být tak robustní.	10
Tvar kontury	Vybíráme dle nejbližší podobnosti vzhledem k hledanému objektu a velikost volíme dle velikosti objektu.	kruh, $r=5\text{ mm}$

Jednotlivé kroky a funkce segmentačního algoritmu jsou diagramem uspořádány (Obrázek 36). Celý proces v diagramu je spouštěn ve dvou cyklických krocích. V prvním z nich jsou dány již zmíněné funkce pro zmenšení obrazů, převedení do formátu s dvojitou datovou přesností a interaktivní inicializací těžiště, což umožní u každého obrazu vymezení inicializační kontury interaktivně, když chceme segmentovat všechny obrazy z vytvořené struktury. Druhý případ použití cyklu byl pro následující kernelovy operace ve zbytku popsaného kódu, aby se algoritmus cyklicky provedl u všech obrazů v dané struktuře.




Obrázek 36: Diagram segmentačního algoritmu dle funkcí.


Jelikož je algoritmus velice časově náročný, proto segmentace jednoho obrazu trvá přibližně 4 minuty. A tak pro získání výsledků z každého obrazu jsou nejprve cyklicky inicializovány všechny kontury ve všech obrazech, a poté se objeví první obraz s vývojovou aktivní konturou, který začne konturu formovat a expanzivně utvářet. Po průchodu všech iterací pro jeden obraz, se obraz uložit do nové 4D maticové struktury. Víceměrná matice nese informaci o obraze s konturou, tedy obrazovou informaci, a taky určuje polohu horizontální a vertikální lokalizace v rámci 4D matice. Takto se nechá po inicializaci kontur ve všech obrazech algoritmus běžet a výsledkem jsou záznamy o všech segmentovaných obrazech uložených v nové 4D matici, které se mohou kdykoli zobrazit a pracovat s nimi dále.

Neefektivní nastavení parametru aktivních kontur (Obrázek 37), kde se vyskytují dva různé extrémy, a to nedostatečná segmentace (vlevo) nebo přehnaná segmentace (vpravo), kde lze vidět, jak kontura vyskočila z hledané srdeční struktury z důvodu filtračního jádra, jelikož nezaznamenala některé z pixelů a zároveň počet iterací byl velice malý na to, aby kontura zůstala v objektu.


Obrázek 38 je naopak vyobrazení postupných iterací aktivní kontury při správném nastavení parametrů, kterými byl algoritmus nastavován v celé práci. Obrázek 39 reprezentuje segmentaci s nastavením správných parametrů v datové sadě I, a zároveň Obrázek 40 ukazuje detailnější segmentovanou oblast zájmu. Obrázek 41 zobrazuje segmentované snímky z dalších datových sad.




Obrázek 37: Neefektivní nastavení aktivní kontury. **Vlevo:** malý počet iterací – 300, časový krok – 0,005 s, jádro o velikosti 10. **Vpravo:** velký počet iterací – 2500, časový krok - 0,1 s, jádro o velikosti 40.




Obrázek 38: Znázorněný vývoj kontury po iteracích.



Obrázek 39: Zobrazení všech segmentovaných předzpracovaných snímků datové sady I.




Obrázek 40: Zobrazení ROI segmentovaných oblastí datové sady I.



Obrázek 41: Ukázky segmentovaných předzpracovaných snímků datové sady II a III.


6.4 Extrakce segmentovaného modelu

Všechny segmentované snímky jsou uloženy ve 4D matici zmíněné v předešlé kapitole. Dále je potřeba segmentovaný objekt odlišit od pozadí, v čemž je relevantní údaj ohledně hodnoty pixelů vně (kladné hodnoty) a uvnitř (záporné hodnoty). Vykreslená kontur na základě barevného mapování energie reflektující konvenci energetické mapy (Obrázek 42) pojednává o energických hladinách v obraze díky barvám. Kontura se dá také zobrazit přehledněji, monochromaticky (Obrázek 43.)



Obrázek 42: Ukázka arteficiálního barevného mapování energetické kontury prvního snímku (datová sada I).

Z rozložení hodnot pixelů (Obrázek 43) lze triviálně přeměnit konturovaný obraz na binární. Klasifikace energie probíhá na základě iterativní separace kladné a záporné konvence energie segmentačního modelu. Tyto nově binarizované snímky se uloží do další 4D matice.




Obrázek 43: Zobrazení kontury na základě monochromatického obrazového spektra prvního snímku (datová sada I).

6.5 Měření parametrů v extrahovaném modelu


Posledním bodem algoritmu procesu aktivních kontur se stalo měření parametrů v srdečních strukturách. V kapitole 6.4 byly všechny odseparované kontury uloženy binárně do 4D matice.

Z výsledků a obrazů je zřejmé, že separované srdeční síně nebo komory nejsou deterministicky definované objekty s měřitelnými parametry. Avšak díky funkcionalitě SW MATLAB, která dokáže extrakci a měření geometrických parametrů binárních objektů, dokážeme určit délku hlavní a vedlejší poloosy objektu, rozměrovou velikost a také těžiště.

Níže (Obrázek 44) je vyobrazen binární obraz prvního obrazu datové sady I, na kterém jsou vysvětleny měřené a hledané parametry. Délka hlavní osy je počítána jako elipsoidní nejdelší vzdálenost v obrazci a délka vedlejší osy zase jako nejkratší elipsoidní vzdálenost v obrazci. Těžiště objektu označeno C je bráno v pixelech jako poloha středu hledaného objektu vzhledem k celému obrazu. Konečný celkový rozměr počítá průměrný v celém obrazci. Vzdálenosti a rozměr byl přepočítán na jednotky délky vzhledem k lepší interpretaci objektivních výsledků, jelikož funkce pro binární obrazy v MATLABu počítá hodnoty v jednotkách pixelů. Přepočet proběhl na základě znalostí rozlišení a velikosti snímků z ultrazvuku, a tak nebylo problém nalézt odpovídající vzdálenost pro jeden pixel, která činila 0,62453 mm/pixel. Tabulka 5 prezentuje výsledky těchto měření v celé datové sadě snímků I.



Obrázek 44: Vlevo: Zobrazení binárního modelu aktivních kontur prvního snímku (datová sada I),
Vpravo: Specifikace měřených parametrů.



Obrázek 45: Zobrazení segmentovaných modelů v binární formě datové sady I.

Tabulka 6 zobrazuje komparaci měřených parametrů s parametry fyziologicky stanovenými levé síně srdeční (Tabulka 5). Další měření tentokrát v pravé síni zobrazuje

Tabulka 7, kde naměřené hodnoty ve všech obrazech datové sady II jsou porovnávány s klinicky stanovenými parametry (Tabulka 8). Při porovnání měřených hodnot se skutečnými jsou měření označeny jako věrohodné a velice efektivní v rámci segmentaci obrazu.

Tabulka 5: Změřené a přepočítané parametry modelu levé srdeční komory ze snímků z datové sady I.

Měřené parametry v LS srdeční				
	Délka hlavní osy [mm]	Délka vedlejší osy [mm]	Těžiště [pixel]	Celkový rozměr [mm]
obr.1	43,3839	27,0946	[274,3157 ; 271,2717]	43,09 × 49,96
obr.2	40,6396	25,3807	[273,0651 ; 282,9080]	37,47 × 43,72
obr.3	42,0311	26,2497	[275,2679 ; 271,8046]	36,85 × 42,45
obr.4	37,3782	23,3438	[279,1507 ; 229,5420]	40,59 × 39,97
obr.5	36,7280	22,9377	[237,2062 ; 285,7027]	37,47 × 36,22
obr.6	41,7501	26,0742	[255,4039 ; 235,7098]	39,35 × 44,34
obr.7	40,2702	25,1500	[284,4155 ; 267,8794]	33,72 × 47,46
obr.8	39,8586	24,8929	[272,2157 ; 246,3205]	33,72 × 38,10
obr.9	31,5729	19,7182	[271,4624 ; 253,0944]	30,60 × 29,35
obr.10	27,4411	17,1378	[250,2347 ; 273,0008]	31,85 × 29,98
obr.11	36,7516	22,9525	[266,1323 ; 223,8502]	40,59 × 50,59
obr.12	25,0832	15,6652	[270,9925 ; 257,6118]	23,11 × 19,98
obr.13	23,9246	14,9416	[295,6745 ; 239,9068]	19,98 × 23,73

Tabulka 6: Porovnání změřených a fyziologických parametrů LS srdeční.

Levá síň				
	Délka hlavní osy [mm]	Délka vedlejší osy [mm]	Plocha [mm/m2]	Těžiště [pixel]
Měřené	39,8586	24,8929	33,72 × 38,10	272,2157 × 246,3205
Fyziologické	25-40 mm			

Tabulka 7: Změřené a přepočítané parametry modelu pravé srdeční komory ze snímků z datové sady

II.

Měřené parametry v PS srdeční				
	Délka hlavní osy [mm]	Délka vedlejší osy [mm]	Těžiště [pixel]	Celkový rozměr [mm]
obr.1	41,7215	24,5710	[165,9503; 160,3232]	33,10 × 39,35
obr.2	45,2083	25,3813	[165,8697; 161,1246]	45,47 × 36,72
obr.3	23,5524	15,0826	[177,4633; 168,7441]	22,85 × 24,35
obr.4	25,7577	16,7723	[176,8557; 166,1576]	26,23 × 25,60
obr.5	25,7342	25,4817	[176,8165; 169,8208]	21,23 × 25,60
obr.6	29,5552	11,6013	[177,3956; 169,7745]	20,60 × 28,10
obr.7	29,1767	11,2714	[178,8136; 170,0958]	19,78 × 29,35
obr.8	29,9922	12,2438	[179,2802; 168,7734]	33,72 × 38,10
obr.9	29,9634	13,6894	[178,1845; 169,6436]	21,85 × 28,73
obr.10	25,3517	19,2543	[181,3245; 173,9309]	20,65 × 24,35
obr.11	22,4509	15,0517	[182,5104; 175,0166]	17,49 × 23,11

Tabulka 8: Porovnání změřených a fyziologických parametrů PS srdeční

Pravá síň				
	Délka hlavní osy [mm]	Délka vedlejší osy [mm]	Plocha [mm/m2]	Těžiště [pixel]
Měřené	25,3517	19,2543	30,65 × 24,35	181,3245 × 17393098
Fyziologické	22-40 mm			

7 Testování algoritmu aktivních kontur

V rámci navržení segmentačního algoritmu byly operativně nastaveny parametry nejvíce vyhovující a přizpůsobující se srdečním strukturám vzhledem k poskytnutým datovým sadám snímků. S touto kvalitou snímků však nelze počítat u každého člověka. Jak už bylo řečeno v teoretické části o problematice viditelnosti srdečních struktur z hlediska proměnlivosti, odlišnosti a různé kvality dat u každého jedince, je potřeba počítat se zhoršenými ultrazukovými výsledky z echokardiografického vyšetření.

V této kapitole bude algoritmus aktivních kontur otestován, a to různými uměle přidanými šumy, o kterých bylo řečeno v kapitole 4.1. Všechny datové sady byly tak uměle degradovány šumovými generátory pro několik parametrů ke každému typu. V kapitole o návrhu a implementaci segmentační procedury (kapitola 6) byla představena databáze uložených snímků, 2D matice v prostředí MATLAB. Pro připomenutí se v prvním sloupci databáze nachází nativní snímky, v druhém nativní snímky převedeny do odstínů šedi a v třetím sloupci jsou snímky předzpracované filtry a úpravou jasu pro lepší viditelnost srdečních struktur.

Do dalších sloupců matice byla uložena nativní data zatížena různými parametry šumu, tak jako je uvedeno níže (Tabulka 9).


Tabulka 9: Zobrazení kompletní testované struktury Im s parametry šumů.

Kompletní struktura testovací databáze Im						
	Nativní data	Monochromatická data	Předzpracovaná data	Gaussův šum	Salt and Pepper šum	Speckle šum
Sloupec	1.	2.	3.	4. - 23.	24. - 43.	44.
Parametry	Původní	Původní	Filttrace, jas	Průměr (m) \in $\langle 0,01; 0,2 \rangle$	Hustota (d) \in $\langle 0,001; 0,02 \rangle$	Rozptyl (v) = 0,04
				Rozptyl (v) = 0,01		


Příklady obrazů s užitými typy šumů a jejich parametry znázorňuje Obrázek 46, Obrázek 48, Obrázek 47. 2D matice se stala kompletní a je připravena jako testovací prostředí. Na všechny obrazy databáze se implementuje metoda aktivních kontur a postupně budou všechny konturované obrazy ukládány do již zmíněné 4D struktury, do dalších sloupců, tak jako v ukládání obrazů v kapitole 6.3 u aplikace algoritmu na nativní data. Příklady šumových obrazů, které jsou ve 4D matici, s vytýčenými aktivními konturami zobrazuje Obrázek 49, Obrázek 51,

Obrázek 50.

GAUSSŮV ŠUM




Obrázek 46: Nativní echokardiografická data ovlivněna syntetickým Gaussovým šumem s deterministicky přidanými parametry a jejich postupným zvyšováním.




Obrázek 47: Nativní echokardiografický snímek ovlivněn syntetickým speckle šumem s deterministicky přidanými parametry.

SALT AND PEPPER ŠUM




Obrázek 48: Nativní echokardiografická data ovlivněna syntetickým Salt and Pepper šumem s deterministicky přidanými parametry a jejich postupným zvyšováním.

GAUSSŮV ŠUM - SEGMENTOVANÁ DATA




Obrázek 49: Zobrazení segmentovaných částí ovlivněných syntetickým Gaussovým šumem s postupně zvyšujícími se parametry.



Obrázek 50: Segmentovaný echokardiografický snímek ovlivněn syntetickým speckle šumem s deterministicky přidanými parametry.

SALT AND PEPPER ŠUM - SEGMENTOVANÁ DATA




Obrázek 51: Zobrazení segmentovaných částí ovlivněných syntetickým Salt and Pepper šumem s postupně zvyšujícími se parametry.

Pro evaluaci konturovaných srdečních struktur je potřeba objekt z obrazu extrahovat. Jelikož se bude počítat s různými druhy podobnostních a chybových operací pro porovnání segmentovaného modelu u nativních snímků se segmentovanými modely z obrazů ovlivněnými šumy, vytvoří se dva různé přístupy, jak konturovanou strukturu separovat.

7.1 Binární extrakce segmentovaného srdečního modelu


Pro první testování parametrů se všechny šumové segmentované kontury, modely převedou do binárního obrazu stejnou metodou jako v kapitole 6.4. dle energetické mapy obrazu se znalostí o kladných a záporných hodnotách vně a uvnitř modelu extrakce. Binární obrazy se vloží do již vytvořené 4D matice jako další sloupce stejně tak jako již u všech zmíněných matic a struktur. Příklady binárních obrazů po segmentaci jsou prezentovány níže (Obrázek 52, Obrázek 53, Obrázek 54).

GAUSSŮV ŠUM - EXTRAHOVANÉ SRDEČNÍ MODELY




Obrázek 52: Extrahované binární modely echokardiografických dat s deterministicky přidatým Gaussovým šumem s postupně zvyšujícími se parametry pro výpočet DICE koeficientu.

SALT AND PEPPER ŠUM - EXTRAHOVANÉ SRDEČNÍ MODELÝ



Obrázek 53: Extrahované binární modely echokardiografických dat s deterministicky přídátým Salt and Pepper šumem s postupně zvyšujícími se parametry pro výpočet DICE koeficientu.



Obrázek 54: Extrahovaný binární model echokardiografického snímku s deterministicky přídátým speckle šumem pro výpočet DICE koeficientu.

7.1.1 Hodnocení DICE koeficientu

V těchto binárních šumových obrazech je potřeba otestovat podobnost a srovnat nativní segmentovaný obraz s každým obrazem pro každý parametr šumu koeficientem DICE, který byl popsán v kapitole 4.2.1. Koeficient pracuje na základě znalosti o množství pixelů obsažených ve dvou měřených obrazech a udává procentuální zastoupení podobnosti, jak už bylo zmíněno (DICE koeficient 4.2.1.).


Tabulka 10: Hodnoty DICE koeficientu pro vybrané parametry šumů z databáze I

Hodnoty DICE koeficientu (%)									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	85,7	83,19	84,88	82,02	97,79	97,86	98,06	97,85	97,05
Obraz 2	87,26	88,89	85,34	88,8	95,15	97,34	97,46	96,46	95,34
Obraz 3	84,84	87,74	85,63	87,77	97,03	96,6	96,66	97,91	80,57
Obraz 4	73,43	76,6	73,53	71,62	91,25	96,06	94,15	96,15	92,3
Obraz 5	88,75	90,58	88,57	88,38	97,28	98,5	98,34	97,91	96,53
Obraz 6	47,44	48,44	46,03	45,96	89,97	88,31	84,68	91,15	76,95
Obraz 7	84,52	82,6	82,77	83,53	98,58	98,99	98,87	96,86	98,39
Obraz 8	92,77	93,9	91,85	92,24	99,56	99,36	99,56	95,54	97,37
Obraz 9	92,53	91,86	94,31	93,79	98,58	98,16	98,53	98,72	89,04
Obraz 10	95,16	95,19	94,87	94,85	99,2	99,28	99,29	99,08	98,08
Obraz 11	68,19	65,38	68,01	70,67	90,91	90,71	97,74	88,68	81,41
Obraz 12	91,74	92,74	92,97	92,28	97,08	97,28	96,39	96,92	74,29
Obraz 13	88,8	88,49	93,42	89,48	96,7	96,05	95,07	96,78	84,39

Tabulka 10 uvádí příklady hodnot spočtených DICE koeficientů pro všechny obrazy. Parametry jednotlivých nastavení jsou popsány taktéž pro jednotlivé sloupce obrazů z databáze. Ze všech použitých parametrů šumu pro všechny obrazy z datové sady I byly stanoveny procentuální intervaly. Každé rozmezí pro určitou hodnotu šumu značí rozsah DICE koeficientu pro všechny obrazy (Tabulka 11).


Tabulka 11: Intervaly hodnot DICE koeficientů pro jednotlivé parametry šumu.

DICE / Gaussův šum										
	(m) $\in <0,01; 0,2>$ (v)= 0,01									
(m)	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09	0,1
[%]	69-97	71-93	84-95	79-95	85-95	82-97	74-97	65-96	85-95	87-95
(m)	0,11	0,12	0,13	0,14	0,15	0,16	0,17	0,18	0,19	0,2
[%]	65-91	64-95	64-85	63-86	70-87	72-87	65-73	72-92	77-91	72-77
DICE / Salt and Pepper šum										
	(d) $\in <0,001; 0,02>$									
(d)	0,001	0,002	0,003	0,004	0,005	0,006	0,007	0,008	0,009	0,01
[%]	98-99	96-99	95-97	94-97	92-97	95-99	91-99	97-98	96-99	98-99
(d)	0,011	0,012	0,013	0,014	0,015	0,016	0,017	0,018	0,019	0,02
[%]	85-91	94-96	97-99	95-98	96-99	97-99	95-96	93-96	94-97	94-97
DICE / Speckle šum										
	(v)=0,04									
	84-98 %									



Obrázek 55: DICE koeficient v závislosti na parametrech Gaussova šumů u všech obrazů v testovací databázi.

Výsledky DICE koeficientů pro všechny obrazy a parametry Gaussova šumu z databáze jsou graficky znázorněny grafem (Obrázek 55), ze kterého lze konstatovat interval podobnostních parametrů mezi hodnotou 65–97 %. Interval podobnosti pixelů z hlediska množství není ideální, ale při shlednutí tvarů jednotlivých kontur lze sledovat občasné odskočení kontury mimo obraz, což mohlo mít za následek právě například jiné množství pixelů, než jako tomu bylo u nativní segmentace. Dále jsou zobrazeny evaluační křivky DICE koeficientu pro dynamickou změnu intenzity šumu Salt and Pepper (Obrázek 56). Výsledky dosahují lepších výsledků ve srovnání s Gaussovým šumem, protože se pohybují v užším intervalu podobností, a to mezi 85–99%.




Obrázek 56: DICE koeficient v závislosti na parametrech Salt and Pepper šumů u všech obrazů v testovací databázi.

7.2 Konturovaná extrakce srdečního modelu

Jiným přístupem lze změřit podobnosti obrazů díky korelaci (COR), střední kvadratické chybě (MSE) nebo strukturální podobnosti obrazů (SSIM), které byly popsány a vysvětleny v kapitole 4.2.


Pro měření těchto parametrů však nelze použít binární obraz. Proto se volí modifikace pro separaci struktury. Tohoto se dosáhne vynásobením 4D matice **segmentovaných obrazů** se 4Dmaticí **binarizovaných obrazů**. Dle zákonitosti energetické mapy konturovaných obrazů po vynásobení vyvstane výsledek se zápornými hodnotami uvnitř objektu a mimo oblast zájmu budou hodnoty nulové. Vynásobením těchto dvou matic se vytvořila nová 2D struktura s názvem a její výstupy jsou představeny níže (Obrázek 57, Obrázek 58, Obrázek 59). Z této struktury byla postupně vybrána relevantní data do jednotlivých struktur pro měření COR, SSIM, MSE a výsledky měření koeficientů byly uloženy do struktur pro celou šumovou databázi obrazů.

GAUSSŮV ŠUM - EXTRAHOVANÉ SRDEČNÍ MODELY, KONTUROVANÉ



Obrázek 57: Extrahované konturované modely echokardiografických dat s deterministicky přidatým Gaussovým šumem s postupně zvyšujícími se parametry pro výpočet SSIM, CORR a MSE.

**SALT AND PEPPER ŠUM - EXTRAHOVANÉ SRDEČNÍ MODELY,
KONTUROVANÉ**



Obrázek 58: Extrahované konturované modely echokardiografických dat s deterministicky přídátým Salt and Pepper šumem s postupně zvyšujícími se parametry pro výpočet SSIM, CORR a MSE.



Obrázek 59: Extrahovaný konturovaný model echokardiografického snímku s deterministicky přídátým speckle šumem pro výpočet SSIM, MSE, CORR.

7.2.1 Hodnocení SSIM

Tabulka 12 pojednává o výsledcích měření strukturálních podobností mezi nativními snímky a všemi uměle zatíženými šumem. Testovaná databáze se skládá s několika desítek sloupců, a proto jsou zde uvedeny pouze jednotlivé příklady spočtených hodnot.

U koeficientu strukturální podobnosti by bylo nejideálnější mít hodnoty 1 u všech obrazů. Z příkladů v tabulce lze pozorovat velice úzký nekolidávající interval hodnot blíží se hodnotě 1, což značí úplnou podobnost modelů. Intervaly hodnot SSIM jsou uvedeny vždy pro určitý parametr šumu (Tabulka 13). Rozpětí hodnot je vždy pro všechny použité obrazy z datové sady. Hodnoty z celé měřené databáze lépe znázorňuje Obrázek 60 a Obrázek 61.


Tabulka 12: Hodnoty SSIM pro vybrané parametry šumů z databáze I

Hodnoty SSIM (-)									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,978	0,979	0,980	0,978	0,985	0,984	0,984	0,984	0,988
Obraz 2	0,985	0,984	0,986	0,984	0,987	0,991	0,990	0,989	0,989
Obraz 3	0,991	0,991	0,991	0,991	0,996	0,995	0,996	0,995	0,987
Obraz 4	0,985	0,985	0,985	0,984	0,991	0,993	0,994	0,992	0,988
Obraz 5	0,992	0,993	0,993	0,992	0,997	0,997	0,997	0,997	0,994
Obraz 6	0,952	0,952	0,950	0,950	0,963	0,961	0,960	0,964	0,960
Obraz 7	0,980	0,980	0,982	0,980	0,990	0,990	0,989	0,987	0,987
Obraz 8	0,991	0,990	0,987	0,988	0,996	0,996	0,996	0,994	0,993
Obraz 9	0,993	0,993	0,993	0,992	0,997	0,997	0,996	0,997	0,991
Obraz 10	0,995	0,994	0,993	0,994	0,999	0,998	0,999	0,999	0,997
Obraz 11	0,981	0,979	0,981	0,982	0,990	0,991	0,993	0,989	0,982
Obraz 12	0,994	0,993	0,994	0,994	0,997	0,996	0,996	0,996	0,988
Obraz 13	0,993	0,993	0,993	0,993	0,996	0,996	0,996	0,995	0,991

Tabulka 13: Intervaly hodnot SSIM pro jednotlivé parametry šumu.


SSIM / Gaussův šum										
(m) ∈ <0,01; 0,2> (v)= 0,01										
(m)	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09	0,1
SSIM (-)	0,992- 0,994	0,990- 0,992	0,994- 0,996	0,991- 0,993	0,992- 0,994	0,992- 0,994	0,992- 0,994	0,982- 0,994	0,980- 0,984	0,952- 0,996
(m)	0,11	0,12	0,13	0,14	0,15	0,16	0,17	0,18	0,19	0,2
SSIM (-)	0,952- 0,994	0,982- 0,994	0,980- 0,986	0,990- 0,994	0,982- 0,998	0,994- 0,996	0,988- 0,992	0,978- 0,984	0,991- 0,993	0,992- 0,994
SSIM / Salt and Pepper šum										
(d) ∈ <0,001; 0,02>										
(d)	0,001	0,002	0,003	0,004	0,005	0,006	0,007	0,008	0,009	0,01
SSIM (-)	0,997- 0,998	0,997- 0,999	0,994- 0,996	0,988- 0,992	0,988- 0,991	0,992- 0,994	0,989- 0,991	0,993- 0,996	0,988- 0,991	0,987- 0,991
(d)	0,011	0,012	0,013	0,014	0,015	0,016	0,017	0,018	0,019	0,02
SSIM (-)	0,989- 0,992	0,996- 0,998	0,996- 0,999	0,984- 0,988	0,991- 0,995	0,985- 0,988	0,987- 0,991	0,997- 0,998	0,987- 0,993	0,991- 0,995
SSIM / Speckle šum										
(v)=0,04										
SSIM (-)	0,961-0,991									

V závislosti strukturálních podobností všech obrazů na parametrech Gaussova šumu, se vyskytuje interval hodnot <0,950; 0,998>. Interval konverguje k 1, tudíž lze konstatovat téměř totožnost komparovaných modelů co se jejich struktury týče. Ukazatel strukturální podobnosti je klíčovým, jelikož značí, že je schopen získat model téměř kopírující ze stejného obrazu i při zvětšení šumu a zatíženosti obrazové informace. Zároveň se pohybuje v kolísání hodnot v malém rozsahu, řádu a neobjevují se tak výkyvy algoritmu v celé databázi.




Obrázek 60: Strukturální podobnosti (SSIM) všech obrazů šumové databáze v závislosti na parametrech Gaussova šumu.

U testování strukturálních podobností u šumu Salt and Pepper se dokonce pohybuje v ještě o něco kvalitnějších výsledcích. Interval SSIM leží mezi $\langle 0,983; 0,999 \rangle$, což o některých obrazech vypovídá skutečnosti téměř stoprocentní podobnosti.




Obrázek 61: Strukturální podobnosti (SSIM) všech obrazů šumové databáze v závislosti na parametrech šumu Salt and Pepper


Další názorné výsledky SSIM prezentují grafy v obrázcích (Obrázek 62, Obrázek 63, Obrázek 64). Pro každý jeden z parametrů šumu, tedy pro každý jeden sloupec v databázi (13 snímků) byl vypočten průměr, medián a rozptyl. Charakteristiky poukazují na statistické parametry průměru, mediánu a rozptylu pro každý parametr šumu a jejich závislost na strukturální podobnosti.



Obrázek 62: Průměry strukturálních podobností jednotlivých obrazů v závislosti na parametrech šumů.



Obrázek 63: Mediány strukturálních podobností jednotlivých obrazů v závislosti na parametrech šumů.



Obrázek 64: Rozptyly SSIM jednotlivých obrazů v závislosti na parametrech šumů.

7.2.2 Hodnocení MSE

Střední kvadratické chyby (Tabulka 14) srovnávají modely z hlediska chybovosti. Čím více konverguje hodnota MSE k nule, tím více lze považovat extrahovaný model z šumových snímků za méně chybný vzhledem k extrahovaným nativním modelům. Vybrané hodnoty chyb dávají tedy najevo hodnoty odchylek. Chybovost se pohybuje v řádu tisícín až setin. Sumarizované intervaly z celé databáze snímků (Tabulka 15) jsou pro každou hodnotu šumu jako intervalová chybovost ve všech snímcích dohromady.


Tabulka 14: Hodnoty MSE pro vybrané parametry šumů z databáze I

Hodnoty MSE (-)									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,035	0,038	0,034	0,041	0,017	0,018	0,017	0,017	0,016
Obraz 2	0,028	0,030	0,029	0,028	0,019	0,013	0,016	0,013	0,013
Obraz 3	0,012	0,011	0,013	0,010	0,004	0,005	0,004	0,005	0,025
Obraz 4	0,024	0,022	0,024	0,026	0,029	0,007	0,008	0,010	0,031
Obraz 5	0,011	0,009	0,010	0,011	0,003	0,004	0,004	0,004	0,007
Obraz 6	0,072	0,070	0,077	0,077	0,015	0,029	0,040	0,001	0,030
Obraz 7	0,035	0,041	0,039	0,037	0,014	0,014	0,016	0,036	0,018
Obraz 8	0,011	0,011	0,017	0,016	0,005	0,006	0,006	0,019	0,008
Obraz 9	0,008	0,008	0,007	0,008	0,004	0,003	0,004	0,004	0,012
Obraz 10	0,006	0,007	0,007	0,006	0,002	0,003	0,002	0,002	0,004
Obraz 11	0,076	0,084	0,079	0,074	0,054	0,052	0,044	0,067	0,034
Obraz 12	0,008	0,008	0,007	0,007	0,004	0,005	0,005	0,005	0,028
Obraz 13	0,010	0,011	0,010	0,010	0,006	0,006	0,006	0,007	0,018


Tabulka 15: Intervaly hodnot MSE pro jednotlivé parametry šumu.

MSE / Gaussův šum										
	(m) \in <0,01; 0,2> (v)= 0,01									
(m)	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09	0,1
MSE (-)	0,005- 0,015	0,025- 0,045	0,008- 0,013	0,016- 0,019	0,003- 0,024	0,022- 0,032	0,012- 0,024	0,012- 0,023	0,021- 0,034	0,005- 0,084
(m)	0,11	0,12	0,13	0,14	0,15	0,16	0,17	0,18	0,19	0,2
MSE (-)	0,007- 0,011	0,007- 0,040	0,006- 0,044	0,011- 0,015	0,013- 0,028	0,015- 0,021	0,020- 0,026	0,017- 0,024	0,010- 0,023	0,005- 0,015
MSE / Salt and Pepper šum										
	(d) \in <0,001; 0,02>									
(d)	0,001	0,002	0,003	0,004	0,005	0,006	0,007	0,008	0,009	0,01
MSE (-)	0,025- 0,035	0,007- 0,013	0,021- 0,036	0,009- 0,022	0,008- 0,019	0,012- 0,024	0,006- 0,019	0,002- 0,054	0,003- 0,052	0,002- 0,044
(d)	0,011	0,012	0,013	0,014	0,015	0,016	0,017	0,018	0,019	0,02
MSE (-)	0,001- 0,067	0,024- 0,035	0,025- 0,035	0,010- 0,031	0,017- 0,028	0,007- 0,022	0,021- 0,033	0,021- 0,035	0,015- 0,035	0,015- 0,034
MSE / Speckle šum										
	(v)=0,04									
MSE (-)	0,004-0,034									

Vykreslené grafy z tabulky výše jsou níže (Obrázek 65 a Obrázek 66). Interval MSE u Gaussova šumu leží v rozmezí <0,005; 0,084 > a můžeme tak zhodnotit modely jako poměrně nevychýlené z hlediska spočtených chyb a minimální. Obdobných výsledků se dosahuje u šumu Salt and Pepper, který se pohybuje také v úzkém intervalu chyb <0,003; 0,067>, ale dochází k občasným výkyvům v měřených chybách u obrazů prostřednictvím viditelných peaků v grafu.




Obrázek 65: Střední kvadratická chyba (MSE) všech obrazů šumové databáze v závislosti na parametrech Gaussova šumu




Obrázek 66: Střední kvadratická chyba (MSE) všech obrazů šumové databáze v závislosti na parametrech šumu Salt and Pepper


Popsaným skutečností a výsledkům (Obrázek 65 a Obrázek 66) odpovídají průběhy níže (Obrázek 67, Obrázek 68, Obrázek 69). Kvůli občasným kolísajícím chybám u šumu Salt and Pepper se při spočtení průměrů, mediánů a rozptylů MSE, pro každý parametr šumu, objevuje právě kolísavost hodnot a nerovnoměrné diskrétní křivky na rozdíl od výsledků u Gaussova šumu, kde jsou parametry stabilnější.



Obrázek 67: Průměry středních kvadratických chyb jednotlivých obrazů v závislosti na parametrech šumů.



Obrázek 68: Mediány středních kvadratických chyb jednotlivých obrazů v závislosti na parametrech šumů.



Obrázek 69: Rozptyly středních kvadratických chyb jednotlivých obrazů v závislosti na parametrech šumů.

7.2.3 Hodnocení CORR

Tabulka 16 popisuje vybrané hodnoty korelací a vymezuje tak přímou závislost nativních a šumových modelů. Všechny hodnoty korelací jsou kladné, a proto předpokládá přímou závislost obrazů. Výsledky konvergují k 1 a pojednávají tak o vysoké podobnosti srovnávaných modelů. Intervaly korelací jsou zobrazeny (Tabulka 17) pro každou hodnotu šumu z databáze. Celá databáze korelačních koeficientů je graficky vykreslena (Obrázek 70, Obrázek 71).


Tabulka 16: Hodnoty CORR pro vybrané parametry šumů z databáze I

Hodnoty CORR (-)									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,828	0,815	0,832	0,797	0,923	0,917	0,921	0,923	0,930
Obraz 2	0,813	0,804	0,810	0,812	0,887	0,923	0,903	0,919	0,921
Obraz 3	0,872	0,884	0,871	0,894	0,957	0,953	0,958	0,953	0,750
Obraz 4	0,805	0,819	0,801	0,787	0,822	0,944	0,944	0,931	0,814
Obraz 5	0,875	0,901	0,887	0,877	0,965	0,959	0,962	0,957	0,927
Obraz 6	0,774	0,830	0,803	0,902	0,793	0,920	0,870	0,752	0,677
Obraz 7	0,822	0,787	0,803	0,811	0,934	0,933	0,928	0,847	0,918
Obraz 8	0,930	0,925	0,891	0,897	0,967	0,964	0,964	0,892	0,948
Obraz 9	0,923	0,925	0,927	0,916	0,964	0,969	0,965	0,964	0,887
Obraz 10	0,944	0,933	0,927	0,938	0,981	0,975	0,979	0,978	0,962
Obraz 11	0,774	0,777	0,863	0,882	0,956	0,964	0,930	0,819	0,848
Obraz 12	0,910	0,909	0,918	0,916	0,956	0,951	0,947	0,947	0,691
Obraz 13	0,895	0,885	0,893	0,894	0,939	0,937	0,934	0,932	0,812


Korelační koeficienty v závislosti na Gaussovém šumu vymezují interval hodnot $<0,77; 0,99>$, tudíž vyvstává podobnost modelů srovnatelná, ale o něco větší, než tomu bylo například u hodnocení DICE koeficientem. Hodnoty jednotlivých obrazů lze označit za nekolísavé a vcelku stabilní. U šumu Salt and Pepper leží interval korelací mezi $<0,75; 0,99>$, což je rozmezí užší, ale naopak zde dochází k občasnému kolísání hodnot u některých obrazů a parametrů. Hodnoty sice více konvergují k přímé závislosti mezi obrazy, ale nejsou dokonale stabilní.

Tabulka 17: Intervaly hodnot CORR pro jednotlivé parametry šumu.

CORR / Gaussův šum										
	(m) $\in <0,01; 0,2>$ (v)= 0,01									
(m)	0,01	0,02	0,03	0,04	0,05	0,06	0,07	0,08	0,09	0,1
CORR (-)	0,882- 0,961	0,890- 0,962	0,894- 0,962	0,891- 0,963	0,892- 0,954	0,782- 0,942	0,791- 0,899	0,912- 0,932	0,888- 0,915	0,774- 0,944
(m)	0,11	0,12	0,13	0,14	0,15	0,16	0,17	0,18	0,19	0,2
CORR (-)	0,777- 0,993	0,801- 0,927	0,787- 0,938	0,799- 0,854	0,892- 0,995	0,894- 0,997	0,988- 0,992	0,928- 0,984	0,911- 0,993	0,892- 0,954
CORR / Salt and Pepper šum										
	(d) $\in <0,001; 0,02>$									
(d)	0,001	0,002	0,003	0,004	0,005	0,006	0,007	0,008	0,009	0,01
CORR (-)	0,897- 0,998	0,797- 0,857	0,874- 0,996	0,788- 0,992	0,798- 0,891	0,872- 0,994	0,859- 0,891	0,793- 0,981	0,797- 0,875	0,870- 0,979
(d)	0,011	0,012	0,013	0,014	0,015	0,016	0,017	0,018	0,019	0,02
CORR (-)	0,752- 0,978	0,996- 0,998	0,996- 0,999	0,884- 0,898	0,791- 0,895	0,905- 0,988	0,887- 0,891	0,907- 0,998	0,901- 0,953	0,991- 0,995
CORR / Speckle šum										
	(v)=0,04									
CORR (-)	0,677-0,962									




Obrázek 70: Korelace (CORR) všech obrazů šumové databáze v závislosti na parametrech Gaussova šumu.




Obrázek 71: Korelace (CORR) všech obrazů šumové databáze v závislosti na parametrech šumu Salt and Pepper



Statistické průměry, mediány a rozptyly korelací pro každý parametr šumu vykreslují průběhy (Obrázek 72, Obrázek 73 a Obrázek 74). U šumu Salt and Pepper se kolísání hodnot projevuje nejvýznamněji mezi hodnotami rozptylů a v průměrech a mediánech těchto hodnot nemají přílišný vliv, tudíž nejsou tak významné a časté.



Obrázek 72: Průměry korelací jednotlivých obrazů v závislosti na parametrech šumů.




Obrázek 73: Mediány korelací jednotlivých obrazů v závislosti na parametrech šumů.




Obrázek 74: Rozptyly korelací jednotlivých obrazů v závislosti na parametrech šumů.

7.3 Dynamické sledování srdečních parametrů

Pro dynamické sledování srdečních parametrů byly vybrány snímky z datové sady II, která se skládá ze snímků vytvořených přímo z echokardiografického video záznamu. Těchto 8 snímků zobrazených níže (Obrázek 75) jsou dále předzpracovány s opětovným užitím algoritmu aktivních kontur.




Obrázek 75: Nativní dynamická sada snímků.



Obrázek 76: Segmentované snímky aktivních kontur v dynamickém režimu. Iterace – 1800, časový krok 0,005 s, velikost jádra 10.

Algoritmus aktivních kontur byl použit s totožným nastavením všech parametrů a jednotlivé segmentace vznikly postupně za sebou (Obrázek 76). Díky segmentaci, je algoritmus schopen podrobit snímky segmentaci v řezu za sebou, a tím určit jejich měřené parametry. Po binarizaci obrazů (Obrázek 77) bylo provedeno měření v tomto případě pravé síně srdeční ve všech obrazech a následně byly výsledky zaznamenány (Tabulka 18).



Obrázek 77: Sekvence binárních modelů aktivních kontur dynamického cyklu.

Tabulka 18: Měřené parametry v PS srdeční pro dynamickou sadu snímků.

Měřené parametry v PS srdeční				
	Délka hlavní osy [mm]	Délka vedlejší osy [mm]	Těžiště [pixel]	Celkový rozměr [mm]
obr.1	40,7215	24,4710	[167,9503; 160,3232]	33,10 × 39,35
obr.2	47,2083	25,3813	[165,8697; 161,1246]	45,47 × 36,72
obr.3	23,5524	15,0726	[177,4633; 168,7441]	21,85 × 24,35
obr.4	23,7577	16,7723	[176,8557; 166,1576]	26,23 × 25,60
obr.5	25,7342	15,4817	[176,8165; 169,8208]	21,23 × 25,60
obr.6	29,9552	14,6013	[177,3956; 189,7745]	20,60 × 28,10
obr.7	25,1557	11,2314	[178,8136; 170,0958]	19,98 × 29,35
obr.8	29,9922	12,5438	[179,2802; 168,7734]	33,72 × 38,10

V rámci segmentované pravé síně srdeční, byly měřeny parametry (Tabulka 18). Síně se podobu srdečního cyklu měnila a formovala, a tudíž docházelo k postupným změnám obrazů, a také ke změnám velikostí segmentovaných částí. V prvním dvou obrazech byl celkový rozměr největší, jelikož srdeční síň byla pravděpodobně ve fázi systolické. Postupně pohybem srdce se pravá srdeční síň formovala a měnila, a tak měnila své rozměry a parametry. Jednotlivé přepočty z pixelů obrazu na milimetry byly vypočítány ze znalostí o poskytnutých ultrazvukových snímcích s přepočtem jednoho pixelu na jednotku délky. Poté již nebyl problém zjistit rozměr v milimetrech. Jednotlivé rozměry se dají pokládat za relevantní z hlediska zjištěných parametrů srdečních v teoretických částech práce, kde rozměr pravé srdeční síně je měněn v důsledku aktuální fáze srdeční od 28-40 mm.


7.4 Sledování srdečních struktur v patologických nálezech

Na základě rozboru pořízených echokardiografických snímků u konkrétních jedinců s různými patologiemi byly provedeny segmentace srdečních struktur u klinických nálezů. Všechna nativní data této kapitoly byly předzpracovány předešlým nastavením v minulých kapitolách a následně segmentovány se stejným nastavením aktivních kontur s proměnlivou hodnotou pro velikost inicializační kružnice, jelikož byla segmentována data s jiných pohledů srdečních os, a tudíž byly velikosti srdečních struktur pro algoritmus rozdílné.

7.4.1 Mírná dilatace síní


Následující obrazová data zobrazují výsledky z vyšetření u pacienti s mírnou dilatací, tedy patologickým rozšířením síní, poruchou relaxace a lehkou nedomykavostí dvojcípé chlopně (chlopeň mezi levou síní a komorou).

Obrázek 78 zobrazuje nativní snímek s následnou segmentací dvou srdečních struktur. Nastavení aktivní kontury bylo při počtu iterací 1800 s časovým krokem 0,005 s a velikostí jádra 10. U segmentovaného snímku vlevo byla velikost kružnice nastavena na 10 mm a u snímku vpravo na 13 mm.



Obrázek 78: Nahoře: Nativní snímek pacienta s mírnou dilatací síní I, dole: předzpracované segmentované snímky srdečních struktur.

Další segmentace (Obrázek 79) o totožné patologie byla nastavena s počtem iterací na 1800 o časovém kroku 0,005 s a velikostí jádra 10 pro velikost inicializační kružnice 10 mm u snímku vlevo a 13 mm u snímku vpravo.




Obrázek 79: Nahoře: nativní snímek u pacienta s mírnou dilatací síní II, dole: předzpracované segmentované snímky srdečních struktur.

7.4.2 Fibrilace síní


Další indikací pro vyšetření byla fibrilace síní, u které vznikla značná dilatace srdečních síní s mírným rozšířením aorty s mírnou nedomykavostí dvojčípe (mitrální) chlopně.

Obrázek 80 prezentuje nativní snímek u pacienta s fibrilací síní s následným předzpracováním a segmentací. Volba parametrů byla s počtem iterací 1800 o velikosti časového kroku 0,005 s a velikostí jádra 10. Inicializační kontura u obou snímků byla nastavena na velikost 8 mm.



Obrázek 80: Nahoře: nativní snímek u pacienta s fibrilací síní I, dole: předzpracované segmentované srdeční struktury.


Obrázek 81 vyobrazuje další segmentace u tohoto patologického nálezu s totožným nastavením parametrů aktivní kontury a následnou velikostí inicializační kružnice u snímku vlevo 8 mm u snímku vpravo 5 mm.



Obrázek 81: Nahoře: nativní snímek u pacienta s fibrilací síní II, dole: předzpracované segmentované srdeční struktury.

7.4.3 Dilatace levostranných oddílů

Následující vyšetření bylo provedeno pro indikaci z důvodu rozšíření levostranných oddílů srdečních. Všechna data vlevo (Obrázek 82) jsou nativní a vpravo jsou uvedeny předzpracované snímky s jejich následnými segmentacemi. Počet iterací se udal na 1800 s velikostí časového kroku 0,005 s o velikosti jádra 10 a velikostí inicializačních kontur o rozměru 8 mm.

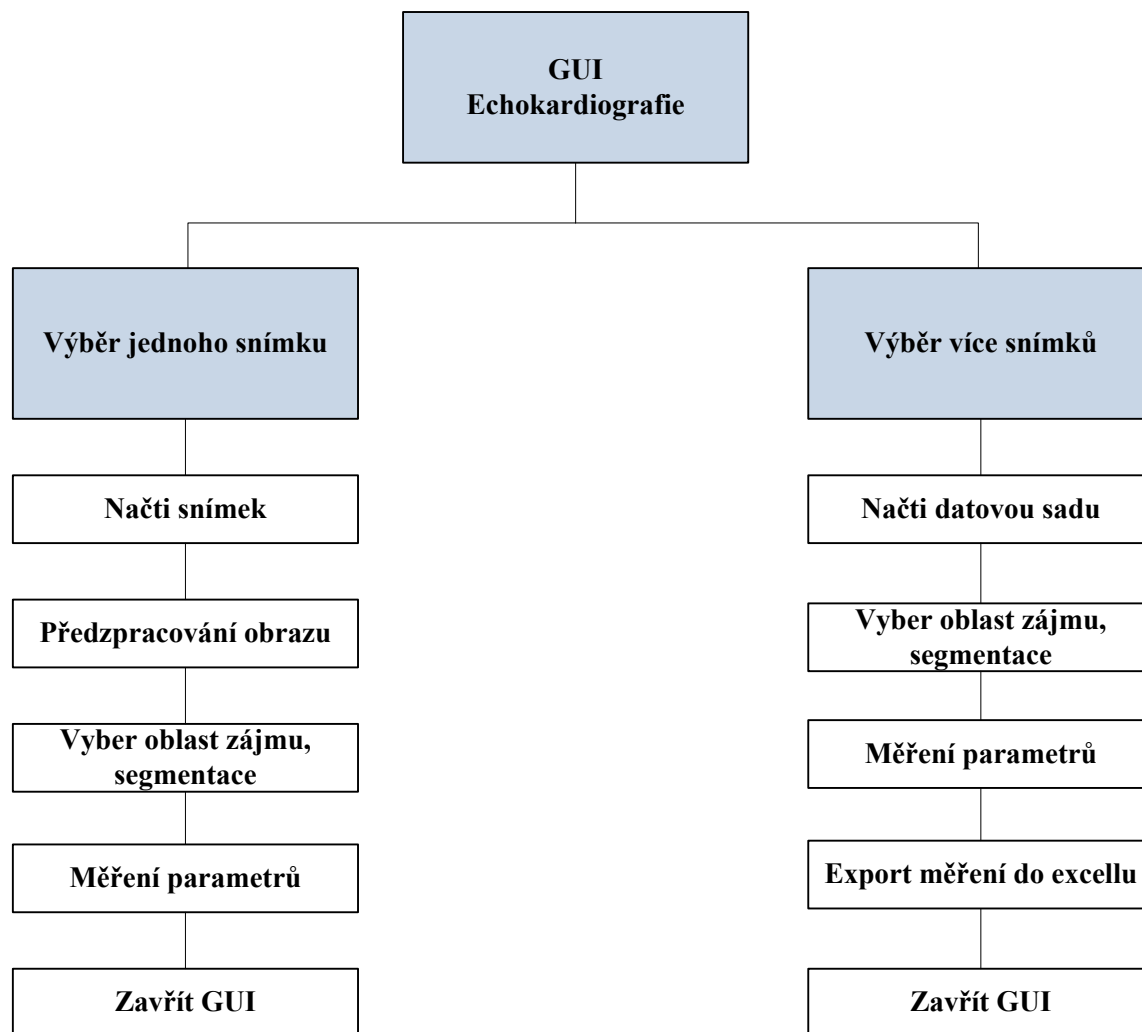


Obrázek 82: Vlevo: Nativní data u levostranných dilatací, vpravo: přezpracované segmentace srdečních struktur.

8 Graficko-uživatelské rozhraní pro modelování zájmových struktur z Echokardiografie

Konečným výsledkem celé implementace a testování bylo vytvoření graficko-uživatelského rozhraní pro segmentaci srdečních síní a komor jak pro výběr jednoho snímku, tak pro výběr celé datové sady snímků s následnou poloautomatickou segmentací v celé datové sadě snímků.

Vývoj a funkce celého GUI je popsán (Obrázek 83), kde lze vidět postupný vývoj rozhraní. Jednotlivé funkce celého SW budou popsány v následujících podkapitolách.



Obrázek 83: Vývojový diagram graficko-uživatelského rozhraní algoritmu pro segmentaci srdečních struktur.

Prvním oknem po otevření základního souboru je úvodní uvítací rozhraní, které dává na výběr zvolení typu segmentace, tedy jestli se bude segmentovat pouze jeden konkrétní snímek, nebo například celá dynamická sada z vyšetření. Obrázek 84 vyobrazuje úvodní okno sestaveno ze dvou ovládacích prvků. Prvním z nich je výběr snímku, který umožní se přesunout do druhého graficko-uživatelského rozhraní, kde je inicializován, segmentován a následně měřen pouze jeden snímek. Druhým ovládacím prvkem je výběr datové sady snímků, kde je SW přesměrován do jiného, třetího GUI, kde se dostává k multiregionální poloautomatické segmentaci a je možno tak segmentovat a měřit dynamickou sadu snímků. Toto GUI představuje modré bloky v diagramu (Obrázek 83)



Obrázek 84: Úvodní okno GUI pro výběr segmentovaných oblastí.

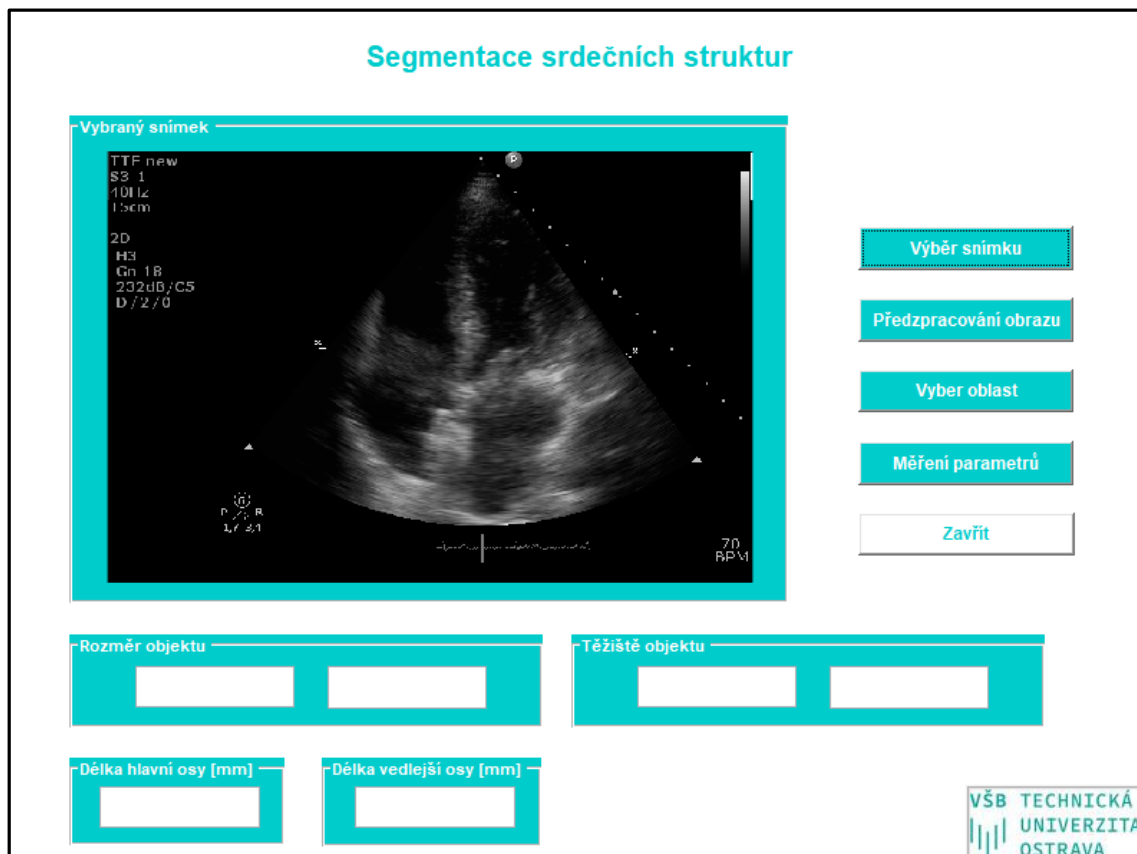
8.1 Výběr jednoho snímku

Po výběru ovládacího prvku **Výběr snímku** (Obrázek 84) je uživatel přesměrován do GUI (Obrázek 85), které disponuje funkcemi zakomponovanými v ovládacích prvcích popsaných v bodech:



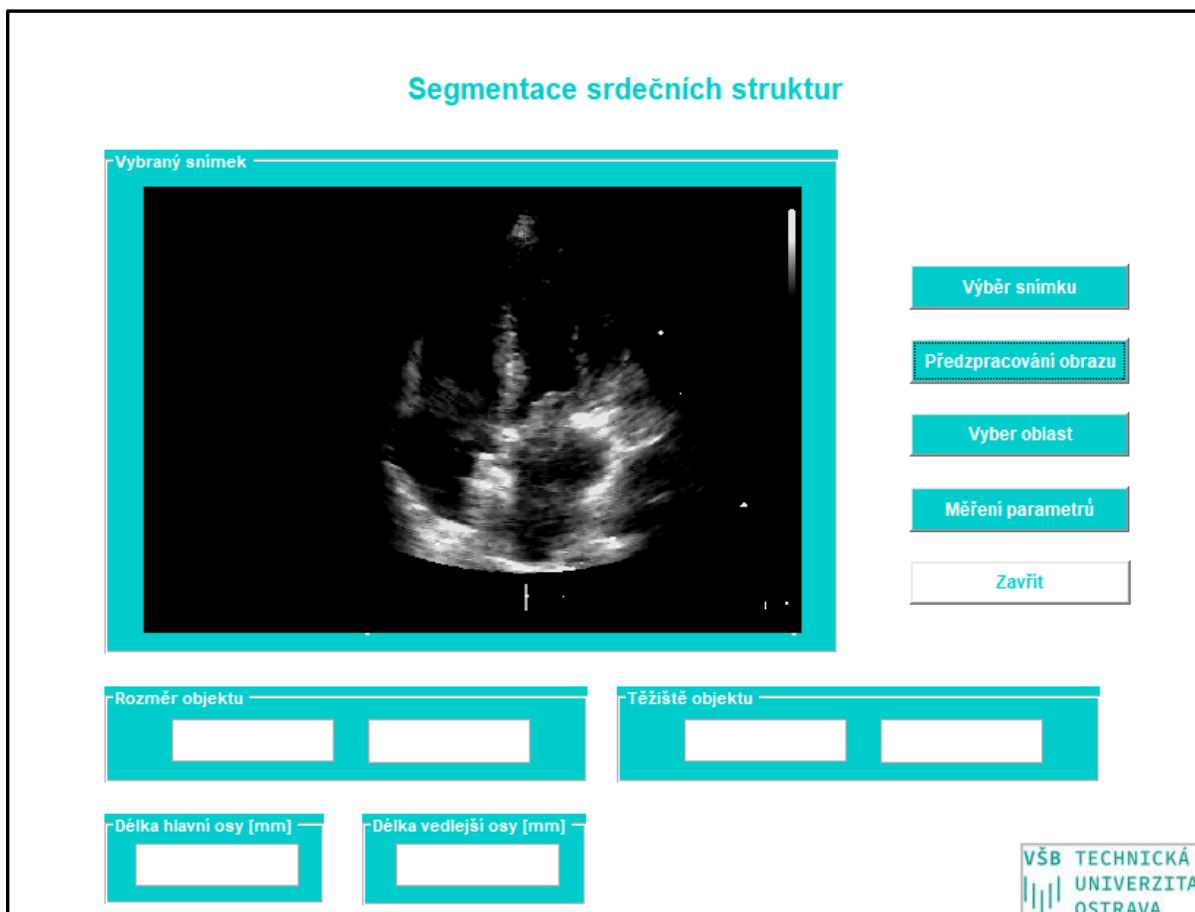
Obrázek 85: GUI výběr jednoho snímku.

1. **Výběr snímku:** Přesměrování uživatele do procházejícího průzkumníku, který umožní najít obrazové soubory s příponami .png, .jpg, .jpeg, .bmp ve složce, kde je uložen právě tento SW. Po výběru je uživatel přesměrován zpátky do GUI, kde se obrazová informace načte, což je znázorněno (Obrázek 86).



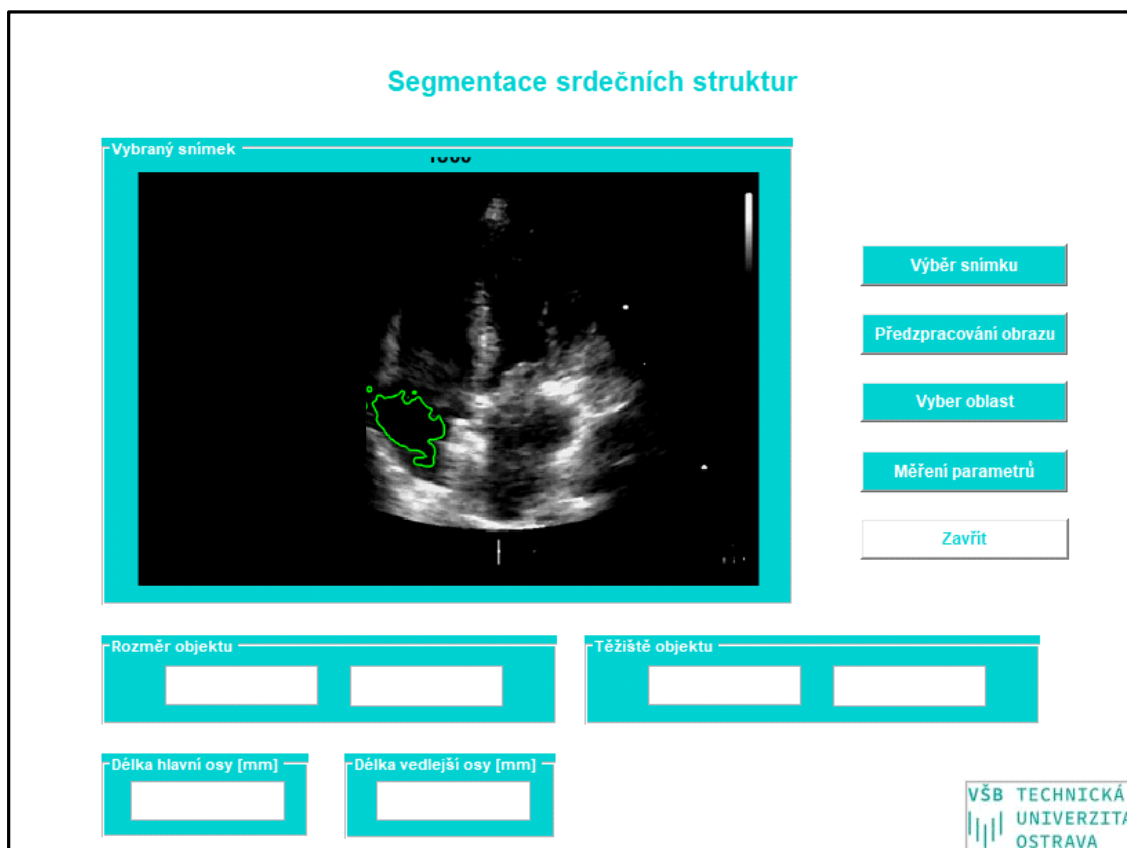
Obrázek 86: GUI pro výběr jednoho snímku, Výběr snímku.

2. **Předzpracování obrazu:** Provede sérii operací, které jsou volané ze samostatného skriptu *preprocess*, díky níž se provádělo předzpracování obrazu i v předešlých kapitolách pro úpravu viditelnosti zájmových srdečních struktur. Jedná se o zesílení a úpravu jasu, hranový filtr a mediánový filtr. Předpracovaný obraz se poté objeví místo původního načteného tak jako lze vidět (Obrázek 87).



Obrázek 87: GUI pro výběr jednoho snímku, Předzpracování obrazu.

3. **Výběr oblasti:** Po předzpracování obrazu předchozí operací je výchozím v obraze určit místo segmentované části. Vybrat inicializační oblast kontury dle požadované srdeční struktury, tedy pravé síně, komory nebo levé síně, komory. Inicializace probíhá manuálním kliknutím nejlépe do středu oblasti zájmu. Po kliknutí se zobrazí inicializační kruh kontury zelenou barvou a dále probíhají jednotlivé iterace a operace celého algoritmu procesu segmentace. Po segmentaci lze vidět vypreparovaný ohraničený model (Obrázek 88)



Obrázek 88: GUI pro výběr jednoho snímku, Vyber oblast.

4. **Měření parametrů:** Po segmentaci obrazu přichází konečná operace pro měření rozměrů a plochy konkrétně levé síně srdeční. Dochází k převedení obrazu do binární podoby, kde se poté provede díky funkci *regionprops* měření právě v binarizované části obrazu. Následně se přímo v grafickém okně objeví měřené výsledky pro segmentovanou levou síň (Obrázek 89) s převedením na jednotky délky dle údajů o konkrétních echokardiografických snímcích.




Obrázek 89: GUI pro výběr jednoho snímku, Měření parametrů.


5. **Zavřít:** Posledním krokem je zavření celého GUI, a tím ukončení SW.

8.2 Výběr datové sady snímků

Po výběru ovládacího prvku **Výběr datasetu snímků** (Obrázek 84), je uživatel přesměrován do GUI, které umožňuje načtení obrazů umístěných ve složce totožné jako skript GUI. Jak už bylo zmíněno v předchozích kapitolách o segmentaci aktivními konturami, je zřejmé, že algoritmus je velice časově náročný. Tudiž, kdyby bylo potřeba segmentovat široký dataset například o 100 snímcích, uživatel by se dobral výsledků segmentací přibližně za několik hodin. Tudiž pro toto uživatelské rozhraní byl dataset omezen výběrem pouze na 6 snímků z dynamického zobrazení, tak jako v kapitole 7.3 (6 grafických oken, Obrázek 90).




Obrázek 90: GUI pro výběr datasetu snímků.



Obrázek 91: Inicializační okno pro všechny obrazy.

1. **Vyber oblast zájmu:** Po inicializaci ovládacího prvku se objeví jedno samostatné grafické okno postupně se všemi snímky již v předzpracované fázi obrazu pro viditelnost srdečních struktur. Inicializací (kliknutím) do jednoho snímku v tomto okně (Obrázek 91), se ukáže snímek další, a tak se postupně inicializují všechny kontury do všech obrazů, které se pak objeví ve grafických oknech (Obrázek 92)



Obrázek 92: GUI pro výběr datasetu snímku, Vyber oblast zájmu.

2. **Měření:** Dalším krokem je měření ve všech segmentovaných oblastech po inicializaci ovládacího prvku Měření (Obrázek 91).
3. **Export/excel:** Výsledky měření jsou exportovány do formátu MS Excel, kde jsou rozděleny měření pro délku hlavní osy, vedlejší osy, těžiště a plochu srdeční struktury s přepočtem na jednotky délky dle parametrů a údajů konkrétních echokardiografických snímků.
4. **Zavřít:** Ukončení a zavření celého GUI.

9 Závěr

Objektivní hodnocení srdečních struktur z echokardiografického vyšetření v klinické praxi je poměrně náročné z hlediska obtížnější viditelnosti a klasifikací srdečních struktur způsobené vitalitou, věkem, tělesnou stavbou jedince a v neposlední řadě frekvencí ultrazvukové sondy, která musí být v menších hodnotách pro dosažení hloubky pro snímání srdce. V případě této práce bylo potřeba tuto problematiku zobjektivizovat a vyvinout segmentační algoritmus dostatečně robustní, aby tento aspekt dokázal zobjektivnit a pomoci tak v klinické praxi k lepší viditelnosti srdečních síní a komor., protože klinický pohled je často rozdílný.

Úkolem této práce bylo z různých datových sad od odlišných jedinců odseparovat srdeční struktury a měřit v nich srdeční parametry jak v dynamickém, tak statickém režimu s rozlišením hranic struktur v různých fázích srdce, což je klíčovým pro správnou diagnostiku a rozeznání srdečních patologií.

Z nastudovaných publikací byl pro tuto práci vybrán segmentační algoritmus založený na geometrických expanzivních aktivních konturách, tedy na statistickém rozložení pixelů. Celý algoritmus byl navržen a nastaven v prostředí MATLAB dle chování v předzpracovaných snímcích všech třech datových sadách (statická datová sada I- 13 snímků, dynamická datová sada II- 11 snímků, statická datová sada III- 12 snímků). Předzpracování obrazů proběhlo na základě jasových transformací, zvýraznění hran v obraze a mediánové filtraci. Po aplikaci nastaveného segmentačního algoritmu byly modely srdečních struktur extrahovány a následně v nich byly měřeny srdeční parametry, a to délka, šířka, těžiště a objem srdeční síně nebo komory (kapitola 6). Implementovaný algoritmus byl poté v kapitole 7 testován, aplikován na všechny datové sady, které byly zatíženy různými parametry šumů (Gaussův šum, Salt and Pepper šum a šum typu speckle). Extrahované modely z obrazů zatížených šumem byly komparovány s modely extrahovanými z předzpracovaných snímků pomocí korelace, strukturální podobnosti, střední kvadratické chyby a koeficientu DICE. Z této analýzy vyvstaly výsledky robustnosti navrženého algoritmu v závislosti na zvyšování šumu v obraze, a tudíž zhoršení kvality a viditelnosti hledaných dat. Výsledky byly vyobrazeny parametricky v tabulkách a také graficky. Z dosažených výsledků lze konstatovat vysokou robustnost algoritmu z hlediska porovnávání modelů. Korelace i strukturální podobnost konvergovala k úplné podobnosti mezi srovnávanými extrahovanými modely, a také střední kvadratické chyby v modelech byly minimální. DICE koeficient se pohyboval v širším intervalu hodnot, ale to v důsledku občasného minimálního vychýlení kontury, kterou bere v potaz. Výsledky datové sady I byly prezentovány v tomto dokumentu a výsledky ostatních datových sad jsou prezentovány v samostatných přílohách práce. Dále bylo sledováno dynamické měření parametrů z dynamické datové sady snímků (kapitola 7.3). Parametry a rozměry segmentované srdeční struktury byly měřeny a porovnány s tabulkovými parametry pro tuto srdeční strukturu s vysoce relevantním výsledkem vzhledem k tabulkovým hodnotám. Poslední částí testování byla segmentace zájmových struktur v patologických nálezech srdečních síní a komor.

Konečným výstupem bylo graficko-uživatelské rozhraní, které disponuje intuitivním ovládáním v segmentaci srdečních struktur, a to jak u statistického obrazu, tak u dynamického setu více snímků s následným měřením a uložením změřených parametrů do samostatných souboru.

10 Zdroje

- [1] MAZAHERI, Samaneh, Puteri Suhaiza Binti SULAIMAN, Rahmita WIRZA, Fatimah KHALID, Suhaini KADIMAN, Mohd Zamrin DIMON a Rohollah Moosavi TAYEBI. Echocardiography Image Segmentation: A Survey. In: 2013 International Conference on Advanced Computer Science Applications and Technologies, IEEE, 2013, s. 327-332]. ISBN 978-1-4799-2758-6.
- [2] CRISTINACCE, D. a T. F. COOTES. Boosted Regression Active Shape Models. In: Proceedings of the British Machine Vision Conference 2007. British Machine Vision Association, 2007, 2007, 79.1-79.10, ISBN 1-901725-34-0.
- [3] DANILOV, V V, I P SKIRNEVSKIY a O M GERGET. Segmentation of anatomical structures of the heart based on echocardiography. Journal of Physics: Conference Series. 2017, 803, 012031, ISSN 1742-6588.
- [4] ZHOU, Shaohua Kevin a Dorin COMANICIU. Shape Regression Machine. KARSSEMEIJER, Nico a Boudewijn LELIEVELDT, ed. Information Processing in Medical Imaging , Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, s. 13-25 Lecture Notes in Computer Science, ISBN 978-3-540-73272-3.
- [5] LACERDA, Saulo Guerreiro, Adson F. DA ROCHA, Daniel F. VASCONCELOS, Joao L. A. DE CARVALHO, Iwens G. SENE a Juliana F. CAMAPUM. Left ventricle segmentation in echocardiography using a radial-search-based image processing algorithm. In: 2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, IEEE, 2008, 2008, s. 222-225, ISBN 978-1-4244-1814-5.
- [6] DEOPUJARI, Shweta, Yogita DUBEY a M.M. MUSHRIF. Left Ventricular Segmentation of 2-D Echocardiographic Image: A Survey. In: 2011 International Conference on Communication Systems and Network Technologies, IEEE, 2011, 2011, s. 563-566 , ISBN 978-1-4577-0543-4.
- [7] DHIMAN, Babita a Surender KUMAR GREWAL. Analysis of Echocardiography Images Using Applications of Image Processing Techniques: A Review , 2014, , 34-38. ISSN 2347-3878. Dostupné z: <http://www.ijser.in/archives/v2i5/SjIwMTMyOTIx.pdf>
- [8] HANSEGÅRD, Jøger, Fredrik ORDERUD a Stein I. RABBEN. Real-time active shape models for segmentation of 3D cardiac ultrasound.
- [9] NILLESEN, Maartje M., Stanislav EMELIANOV, William F. WALKER, et al. Three-dimensional segmentation of the heart muscle using image statistics In: . 2006-3-2, 61470N.
- [10] DIETENBECK, Thomas. Segmentation of 2D-echocardiographic sequences using level-set constrained with shape and motion priors. Lyon, 2013. Dizertační práce.
- [11] MOLNÁROVÁ, Kristýna. Optimalizace ultrazvukových dat hypertrofických jizev po popáleninách. Ostrava, 2017. Bakalářská práce. Vysoká škola báňská, Technická univerzita.
- [12] VESELKA, doc. MUDr. Josef, CSc. Význam dvourozměrné (2D) echokardiografie v diagnostice hypertrofické kardiomyopatie, Kardiologická klinika 2. LF UK a FN v Motole, Praha, 2005.

- [13] PIVODOVÁ, Adriana. Využití ultrazvukového měření tloušťky kůže při kutometrické diagnostice. 2015
- [14] MONDILLO, Sergio, Maurizio GALDERISI, Donato MELE, a Matteo a kol. CAMELI. Speckle Tracking Echocardiography, 2011. ISSN 0278-4297.
- [15] BRYJOVÁ, Iveta. Měření tloušťky kůže pomocí ultrazvuku. 2014
- [16] ZUNA, Ivan a Lubomír POUŠEK. Úvod do zobrazovacích metod v lékařské diagnostice. Praha: České vysoké učení technické v Praze, 2000. ISBN 9788001021521.
- [17] HRUŠKOVÁ, Bc. Jana. Echokardiografický interaktivní atlas základních kardiovaskulárních nemocí. Brno, 2013. Diplomová práce. Vedoucí práce Mudr. Marek Orban.
- [18] STANĚK, Vladimír. Kardiologie v praxi. 1. vyd. Praha: Axonite CZ, 2014, 375 s. Asclepius. ISBN 978-80-904899-7-4.
- [19] LINHART, Aleš. 2D echokardiografie. In: . II. interní klinika kardiologie a angiologie, 1. LF UK a VFN. Dostupné z: <http://int2.lf1.cuni.cz/>
- [20] KRAHULCOVÁ, Mgr. Soňa. Echokardiografické a spiroergometrické parametry u vytrvalostních sportovců, mužů ve věku od 20 do 30 let: Rigorózní práce . Brno, 2007.
- [21] JI, Zexuan, Yong XIA, Quansen SUN, Guo CAO a Qiang CHEN. Active contours driven by local likelihood image fitting energy for image segmentation. *Information Sciences*. 2015, **301**, 285-304 DOI: 10.1016/j.ins.2015.01.006. ISSN 00200255
- [22] *Mathworks*, *SSIM*. USA, 2014. Dostupné také z: <https://www.mathworks.com/help/images/ref/ssim.html>

Seznam příloh

Příloha I


Příloha A: Datová sada II

Příloha B: Datová sada III


Samostatná příloha II

Vypracované kódy na CD, grafy, GUI, měřené parametry (IS Edison)


Příloha A: Datová sada II




Obrázek 93: Datová sada II: nativní snímky.



Obrázek 94: Datová sada II: předzpracované snímky.



Obrázek 95: Datová sada II: segmentované snímky




Obrázek 96: Datová sada II: binarizované snímky.


Tabulka 19: Měřené parametry PS srdeční v datové sadě II.

Měřené parametry v PS srdeční				
	Délka hlavní osy [mm]	Délka vedlejší osy [mm]	Těžiště [pixel]	Celkový rozměr [mm]
obr.1	40,7215	24,4710	[167,9503; 160,3232]	33,10 × 39,35
obr.2	47,2083	25,3813	[165,8697; 161,1246]	45,47 × 36,72
obr.3	23,5524	15,0726	[177,4633; 168,7441]	21,85 × 24,35
obr.4	23,7577	16,7723	[176,8557; 166,1576]	26,23 × 25,60
obr.5	25,7342	15,4817	[176,8165; 169,8208]	21,23 × 25,60
obr.6	29,9552	11,6013	[177,3956; 169,7745]	20,60 × 28,10
obr.7	29,1757	11,2314	[178,8136; 170,0958]	19,98 × 29,35
obr.8	29,9922	12,2438	[179,2802; 168,7734]	33,72 × 38,10
obr.9	29,9634	13,6894	[178,1845; 169,6436]	21,85 × 28,73
obr.10	25,3517	17,3103	[181,3245; 173,9309]	20,65 × 24,35
obr.11	22,4509	15,0517	[182,51054; 175,0166]	17,49 × 23,11


Gaussův šum
M= 0,12, V= 0,01




Gaussův šum
M= 0,13, V= 0,01




Salt and Pepper šum
D= 0,010



Salt and Pepper šum
D= 0,011




Speckle šum
V= 0,04




Obrázek 97: Datová sada II: vybraná šumová data.


Gaussův šum
M= 0,12, V= 0,01




Gaussův šum
M= 0,13, V= 0,01




Salt and Pepper šum
D= 0,010



Salt and Pepper šum
D= 0,011



Speckle šum
V= 0,04



Obrázek 98: Datová sada II: vybraná segmentovaná šumová data.

Gaussův šum
M= 0,12, V= 0,01




Gaussův šum
M= 0,13, V= 0,01




Salt and Pepper šum
D= 0,010



Salt and Pepper šum
D= 0,011



Speckle šum
V= 0,04



Obrázek 99: Datová sada II: vybraná binarizovaná šumová data.

Tabulka 20: Hodnoty korelací vybraných parametrů šumů pro datovou sadu II.

Hodnoty CORR									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,9258	0,9332	0,8981	0,9070	0,9730	0,9800	0,9757	0,9725	0,9577
Obraz 2	0,9408	0,9343	0,9472	0,9496	0,9918	0,9887	0,9949	0,9945	0,9584
Obraz 3	0,9644	0,9537	0,9508	0,9666	0,9931	0,9994	0,9967	0,9949	0,9693
Obraz 4	0,9270	0,9103	0,9684	0,8823	0,9855	0,9852	0,9827	0,9832	0,8778
Obraz 5	0,9445	0,9436	0,9457	0,9529	0,9775	0,9809	0,9782	0,9802	0,9320
Obraz 6	0,9585	0,9302	0,9383	0,9321	0,9845	0,9872	0,9829	0,9802	0,9549
Obraz 7	0,9339	0,9337	0,9651	0,9579	0,9919	0,9872	0,9897	0,9906	0,8536
Obraz 8	0,9281	0,9412	0,9253	0,9514	0,9715	0,9882	0,9717	0,9902	0,9569
Obraz 9	0,9568	0,9451	0,9328	0,9342	0,9832	0,9925	0,9868	0,9902	0,9618
Obraz 10	0,9358	0,9466	0,9242	0,9254	0,9808	0,9596	0,9765	0,9808	0,9457
Obraz 11	0,6679	0,6829	0,6834	0,6933	0,9126	0,9066	0,9241	0,9037	0,8801

Tabulka 21: Hodnoty středních kvadratických chyb vybraných parametrů šumů pro datovou sadu II.

Hodnoty MSE									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,0088	0,0078	0,0120	0,0115	0,0033	0,0025	0,0029	0,0032	0,0051
Obraz 2	0,0060	0,0066	0,0055	0,0051	0,0008	0,0012	0,0005	0,0006	0,0043
Obraz 3	0,0028	0,0036	0,0038	0,0025	0,0005	0,0001	0,0003	0,0004	0,0024
Obraz 4	0,0064	0,0073	0,0025	0,0104	0,0012	0,0012	0,0014	0,0014	0,0111
Obraz 5	0,0049	0,0049	0,0048	0,0041	0,0020	0,0017	0,0019	0,0017	0,0061
Obraz 6	0,0028	0,0048	0,0041	0,0046	0,0011	0,0009	0,0012	0,0014	0,0035
Obraz 7	0,0045	0,0044	0,0022	0,0027	0,0005	0,0008	0,0007	0,0006	0,0111
Obraz 8	0,0059	0,0048	0,0059	0,0040	0,0024	0,0010	0,0023	0,0008	0,0035
Obraz 9	0,0037	0,0048	0,0056	0,0055	0,0015	0,0006	0,0012	0,0008	0,0033
Obraz 10	0,0055	0,0046	0,0064	0,0066	0,0017	0,0035	0,0021	0,0017	0,0046
Obraz 11	0,1347	0,1298	0,1302	0,1264	0,0408	0,0463	0,0348	0,0438	0,2437


Tabulka 22: Hodnoty strukturálních podobností vybraných parametrů šumů pro datovou sadu II.

Hodnoty SSIM									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,9901	0,9920	0,9893	0,9885	0,9965	0,9975	0,9973	0,9970	0,9943
Obraz 2	0,9940	0,9941	0,9946	0,9951	0,9994	0,9993	0,9996	0,9997	0,9969
Obraz 3	0,9968	0,9960	0,9966	0,9973	0,9996	0,9999	0,9998	0,9997	0,9977
Obraz 4	0,9946	0,9934	0,9961	0,9918	0,9986	0,9985	0,9967	0,9974	0,9922
Obraz 5	0,9947	0,9955	0,9947	0,9961	0,9982	0,9986	0,9982	0,9983	0,9956
Obraz 6	0,9962	0,9949	0,9954	0,9950	0,9989	0,9986	0,9984	0,9982	0,9955
Obraz 7	0,9953	0,9952	0,9971	0,9966	0,9990	0,9984	0,9988	0,9983	0,9929
Obraz 8	0,9950	0,9943	0,9942	0,9958	0,9981	0,9983	0,9978	0,9990	0,9963
Obraz 9	0,9955	0,9958	0,9943	0,9939	0,9985	0,9992	0,9986	0,9990	0,9968
Obraz 10	0,9945	0,9944	0,9935	0,9929	0,9979	0,9965	0,9966	0,9976	0,9960
Obraz 11	0,9757	0,9746	0,9764	0,9765	0,9853	0,9856	0,9871	0,9859	0,9605


Tabulka 23: Hodnoty DICE koeficientů vybraných parametrů šumů pro datovou sadu II.

Hodnoty DICE koeficientu									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,8801	0,8917	0,8809	0,8641	0,9183	0,9322	0,9361	0,9486	0,9193
Obraz 2	0,8211	0,8410	0,8557	0,8287	0,8369	0,8498	0,8566	0,8612	0,8332
Obraz 3	0,6584	0,6709	0,6743	0,6671	0,6769	0,6911	0,6971	0,7025	0,6778
Obraz 4	0,7006	0,7111	0,7123	0,7033	0,7137	0,7280	0,7341	0,7385	0,7146
Obraz 5	0,7264	0,7299	0,7394	0,7352	0,7420	0,7561	0,7598	0,7656	0,7406
Obraz 6	0,6501	0,6671	0,6804	0,6611	0,6604	0,6714	0,6757	0,6807	0,6574
Obraz 7	0,7607	0,7727	0,5767	0,5757	0,5829	0,5957	0,5995	0,6021	0,5797
Obraz 8	0,6486	0,6519	0,6562	0,6651	0,6646	0,6741	0,6783	0,6818	0,6679
Obraz 9	0,6432	0,6227	0,6409	0,6606	0,6432	0,6521	0,6561	0,6605	0,6476
Obraz 10	0,6572	0,6474	0,6578	0,6701	0,6687	0,6783	0,6838	0,6887	0,6720
Obraz 11	0,7008	0,4835	0,4837	0,5142	0,5038	0,4949	0,4920	0,4848	0,8030


Příloha B: Datová sada III




Obrázek 100: Datová sada III: nativní snímky.



Obrázek 101: Datová sada III: předzpracované snímky.



Obrázek 102: Datová sada III: segmentované snímky.




Obrázek 103: Datová sada III: binarizované snímky.


Tabulka 24: Měřené parametry PS srdeční v datové sadě III.

Měřené parametry v PS srdeční				
	Délka hlavní osy [mm]	Délka vedlejší osy [mm]	Těžiště [pixel]	Celkový rozměr [mm]
obr.1	56,63912823	44,2115388	[220,3621; 147,3273]	51,3 × 51,61
obr.2	55,19951794	45,21416946	[219,3982; 143,8117]	60,45 × 51,3
obr.3	57,53353282	43,40897767	[219,0595; 142,9633]	51,3 × 57,89
obr.4	59,4023482	47,90691254	[220,9091; 140,8755]	59,44 × 51,74
obr.5	56,34867964	47,96747635	[217,8731; 148,6905]	56,35 × 69,16
obr.6	53,20454894	46,67860394	[220,2193; 145,1717]	59,42 × 48,16
obr.7	51,34556293	45,18276921	[223,8666; 142,4250]	56,87 × 48,67
obr.8	51,52938433	43,1717491	[221,5276; 141,8638]	59,42 × 46,11
obr.9	49,68998933	42,87579079	[224,3366; 139,9361]	49,70 × 45,6
obr.10	49,28638622	42,49452254	[224,4159; 137,8403]	52,26 × 45,08
obr.11	54,40405752	45,53253218	[224,3646; 143,8425]	55,33 × 56,87
obr.12	57,74347477	44,98908425	[223,2206; 141,9098]	60,45 × 51,23


Gaussův šum
M= 0,12, V= 0,01




Gaussův šum
M= 0,13, V= 0,01




Salt and Pepper šum
D= 0,010



Salt and Pepper šum
D= 0,011




Speckle šum
V= 0,04




Obrázek 104: Datová sada III: šumová data.


Gaussův šum
M= 0,12, V= 0,01




Gaussův šum
M= 0,13, V= 0,01




Salt and Pepper šum
D= 0,010



Salt and Pepper šum
D= 0,011



Speckle šum
V= 0,04



Obrázek 105: Datová sada III: segmentované šumové snímky.

Tabulka 25: Hodnoty CORR vybraných parametrů šumů pro datovou sadu III

Hodnoty CORR									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,8957	0,8865	0,8864	0,8913	0,9729	0,9686	0,9701	0,9706	0,9441
Obraz 2	0,8299	0,8240	0,8356	0,8302	0,9513	0,9514	0,9412	0,9435	0,9008
Obraz 3	0,8609	0,8455	0,8673	0,8526	0,9514	0,9509	0,9450	0,9488	0,9205
Obraz 4	0,8605	0,8668	0,8512	0,8554	0,9419	0,9502	0,9491	0,9462	0,9211
Obraz 5	0,8438	0,8540	0,8503	0,8670	0,9531	0,9500	0,9527	0,9544	0,9263
Obraz 6	0,8895	0,8944	0,8969	0,8896	0,9669	0,9718	0,9680	0,9634	0,9415
Obraz 7	0,8875	0,8779	0,8748	0,8702	0,9551	0,9448	0,9540	0,9484	0,9319
Obraz 8	0,8647	0,8545	0,8553	0,8606	0,9519	0,9436	0,9528	0,9506	0,9142
Obraz 9	0,8671	0,8726	0,8676	0,8746	0,9612	0,9654	0,9599	0,9583	0,9233
Obraz 10	0,8843	0,8802	0,8635	0,8774	0,9661	0,9597	0,9505	0,7411	0,9382
Obraz 11	0,6897	0,6944	0,7101	0,7085	0,8146	0,8106	0,8387	0,8164	0,7786
Obraz 12	0,8312	0,8304	0,8153	0,8069	0,9416	0,9075	0,9355	0,9450	0,9094

Tabulka 26: Hodnoty SSIM vybraných parametrů šumů pro datovou sadu III

Hodnoty MSE									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,0927	0,1016	0,1008	0,0976	0,0291	0,0275	0,0270	0,0204	0,0509
Obraz 2	0,1543	0,1591	0,1495	0,1549	0,0471	0,0569	0,0545	0,0602	0,0936
Obraz 3	0,1367	0,1515	0,1308	0,1448	0,0516	0,0578	0,0536	0,0582	0,0816
Obraz 4	0,1300	0,1245	0,1381	0,1344	0,0494	0,0502	0,0530	0,0509	0,0768
Obraz 5	0,1585	0,1489	0,1530	0,1365	0,0541	0,0512	0,0490	0,0424	0,0780
Obraz 6	0,0987	0,0941	0,0919	0,0981	0,0263	0,0298	0,0345	0,0306	0,0540
Obraz 7	0,1027	0,1110	0,1137	0,1177	0,0539	0,0445	0,0496	0,0552	0,0645
Obraz 8	0,1218	0,1303	0,1295	0,1253	0,0535	0,0447	0,0469	0,0438	0,0795
Obraz 9	0,1199	0,1149	0,1194	0,1136	0,0332	0,0388	0,0403	0,0414	0,0720
Obraz 10	0,0916	0,0942	0,1075	0,0967	0,0331	0,0413	0,3147	0,0556	0,0507
Obraz 11	0,3407	0,3362	0,3219	0,3231	0,2245	0,1946	0,2158	0,2117	0,2551
Obraz 12	0,1585	0,1590	0,1721	0,1793	0,0974	0,0655	0,0552	0,0946	0,0896

Tabulka 27: Hodnoty SSIM vybraných parametrů šumů pro datovou sadu III

Hodnoty SSIM									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,9308	0,9285	0,9306	0,9330	0,9755	0,9766	0,9772	0,9826	0,9553
Obraz 2	0,9030	0,9059	0,9069	0,9024	0,9616	0,9562	0,9573	0,9563	0,9196
Obraz 3	0,9124	0,9111	0,9170	0,9097	0,9680	0,9654	0,9624	0,9656	0,9369
Obraz 4	0,9160	0,9215	0,9149	0,9213	0,9641	0,9654	0,9605	0,9629	0,9401
Obraz 5	0,9071	0,9137	0,9150	0,9160	0,9594	0,9597	0,9604	0,9662	0,9368
Obraz 6	0,9270	0,9343	0,9354	0,9291	0,9742	0,9713	0,9707	0,9721	0,9480
Obraz 7	0,9267	0,9245	0,9223	0,9199	0,9654	0,9659	0,9650	0,9610	0,9443
Obraz 8	0,9256	0,9262	0,9286	0,9287	0,9676	0,9706	0,9717	0,9719	0,9461
Obraz 9	0,9267	0,9285	0,9290	0,9288	0,9730	0,9720	0,9727	0,9675	0,9401
Obraz 10	0,9362	0,9339	0,9249	0,9309	0,9759	0,9699	0,9662	0,9657	0,9528
Obraz 11	0,9026	0,9039	0,9115	0,9074	0,9391	0,9467	0,9461	0,9400	0,9147
Obraz 12	0,9201	0,9110	0,9123	0,9116	0,9619	0,9581	0,9629	0,9564	0,9323

Tabulka 28: Hodnoty DICE koeficientů vybraných parametrů šumů pro datovou sadu III.

Hodnoty DICE koeficientu									
	Gaussův šum				Salt and Pepper šum				Speckle šum
Parametr	m=0,1; v=0,01	m=0,11; v=0,01	m=0,12; v=0,01	m=0,13; v=0,01	d=0,008	d=0,009	d=0,010	d=0,011	v=0,04
Obraz 1	0,9031	0,9077	0,8689	0,8399	0,9393	0,9822	0,9671	0,9606	0,9063
Obraz 2	0,8441	0,8570	0,8437	0,6799	0,8579	0,8998	0,8876	0,8732	0,8202
Obraz 3	0,6814	0,6869	0,6623	0,7167	0,6979	0,7411	0,7281	0,7145	0,6648
Obraz 4	0,7236	0,7271	0,7003	0,7450	0,7347	0,7780	0,7651	0,7505	0,7016
Obraz 5	0,7494	0,7459	0,7274	0,6634	0,7630	0,8061	0,7908	0,7776	0,7276
Obraz 6	0,6731	0,6831	0,6684	0,5859	0,6814	0,7214	0,7067	0,6927	0,6444
Obraz 7	0,7837	0,7887	0,5647	0,6676	0,6039	0,6457	0,6305	0,6141	0,5667
Obraz 8	0,6716	0,6679	0,6442	0,6462	0,6856	0,7241	0,7093	0,6938	0,6549
Obraz 9	0,6662	0,6387	0,6289	0,6717	0,6642	0,7021	0,6871	0,6725	0,6346
Obraz 10	0,6802	0,6634	0,6458	0,5538	0,6897	0,7283	0,7148	0,7007	0,6590
Obraz 11	0,7238	0,4995	0,4717	0,6267	0,5248	0,5449	0,5230	0,4968	0,7900
Obraz 12	0,6716	0,6646	0,6366	0,8436	0,5977	0,7920	0,6884	0,8677	0,6590